



Universidad
Zaragoza

Trabajo Fin de Grado

Simulación de la contracción del tejido muscular
esquelético mediante redes neuronales

On using neural networks to simulate skeletal muscle
contraction

Autor

Eva Velamazán Sandalinas

Director

Jorge Grasa Orús

ESCUELA DE INGENIERÍA Y ARQUITECTURA
2021



DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD

(Este documento debe acompañar al Trabajo Fin de Grado (TFG)/Trabajo Fin de Máster (TFM) cuando sea depositado para su evaluación).

TRABAJOS DE FIN DE GRADO / FIN DE MÁSTER

D./D^a. EVA VELAMAZÁN SANDALINAS,

con nº de DNI 73429973N en aplicación de lo dispuesto en el art.

14 (Derechos de autor) del Acuerdo de 11 de septiembre de 2014, del Consejo de Gobierno, por el que se aprueba el Reglamento de los TFG y TFM de la Universidad de Zaragoza,

Declaro que el presente Trabajo de Fin de (Grado/Máster)
GRADO, (Título del Trabajo)
SIMULACIÓN DE LA CONTRACCIÓN DEL TEJIDO MUSCULAR ESQUELÉTICO
MEDIANTE REDES NEURONALES

es de mi autoría y es original, no habiéndose utilizado fuente sin ser citada debidamente.

Zaragoza, 22 JUNIO 2021

Fdo: EVA VELAMAZÁN SANDALINAS

AGRADECIMIENTOS

Me gustaría aprovechar este espacio para agradecer al Dr. Jorge Grasa toda la disposición y dedicación en la dirección de este Trabajo Final de Grado, sin olvidar toda la ayuda recibida, la paciencia y el buen trato recibido durante todos estos meses.

Agradecer a mi familia todo el cariño, el apoyo y la confianza en mí depositada y a mis amigos, por todas las risas y momentos que hemos pasado juntos.

Simulación de la contracción del tejido muscular esquelético mediante redes neuronales

RESUMEN

Este Trabajo Final de Grado tiene como objetivo el desarrollo de una metodología computacional con la capacidad de poder simular la contracción del tejido muscular esquelético en tiempo real.

En primer lugar, se realiza una breve introducción del aprendizaje profundo (*Deep Learning*) y las redes neuronales. Previamente a la predicción de la contracción del tejido utilizando redes neuronales, se realiza un estudio de la simulación computacional del tejido musculo esquelético empleando un software de elementos finitos. Para ello, se describe el comportamiento del tejido durante la contracción, incluyendo el comportamiento pasivo y el activo, y se simulan distintas geometrías tridimensionales para estudiar y analizar la respuesta del tejido ante la variación de diferentes parámetros.

Posteriormente, se han utilizado estos modelos tridimensionales para generar las muestras para el entrenamiento de las redes neuronales, las cuales generarán una predicción del comportamiento del músculo durante la contracción muscular.

Por último, se analizará y discutirá las predicciones obtenidas mediante las redes neuronales con los resultados obtenidos mediante el software de elementos finitos, con el objetivo de comprobar la validez de esta metodología en la simulación del tejido muscular.

Índice

1. Introducción	1
1.1. El tejido muscular	1
1.2. Músculo estriado esquelético	3
1.3. Objetivos	5
1.4. Descripción de la memoria	6
2. Aprendizaje Profundo (<i>Deep Learning</i>) y Redes Neuronales	9
2.1. La Inteligencia Artificial	9
2.1.1. Aplicaciones de la Inteligencia Artificial	10
2.2. Aprendizaje Automático (<i>Machine Learning</i>) y Aprendizaje Profundo (<i>Deep Learning</i>)	11
2.2.1. Ejemplo de aplicación sencilla de ambas técnicas	12
2.3. Aprendizaje Profundo (<i>Deep Learning</i>) y Redes Neuronales	12
2.3.1. Aprendizaje profundo	12
2.3.2. Redes neuronales	13
2.3.2.1. Funcionamiento de las redes neuronales	14
2.3.2.2. Entrenamiento de las redes neuronales	15
2.3.2.3. Funciones y aplicación de las redes neuronales	15
3. Simulación computacional del tejido músculo-esquelético	17
3.1. Modelado del tejido músculo-esquelético	17
3.1.1. Comportamiento pasivo	18
3.1.2. Comportamiento activo	19

3.2. Simulación de geometrías idealizadas	21
3.2.1. Modelo idealizado	21
3.2.1.1. Tensión isométrica máxima, P_0	26
3.2.1.2. Parámetro constitutivo, v_0	27
3.2.1.3. Dimensiones características	28
3.2.1.4. Parámetro de fricción, ν	29
3.2.1.5. Tensión isométrica máxima, P_0 y parámetro constitutivo, v_0	30
3.2.1.6. Parámetro constitutivo, v_0 y parámetro de fricción, ν	31
3.2.1.7. Contracción concéntrica	32
3.2.2. Modelo de geometría fusiforme	35
3.2.2.1. Tensión isométrica máxima, P_0	40
3.2.2.2. Parámetro constitutivo, v_0	41
3.2.2.3. Dimensiones características	41
3.2.2.4. Parámetro de fricción, ν	43
3.2.2.5. Tensión isométrica máxima, P_0 y parámetro constitutivo, v_0	43
3.2.2.6. Parámetro constitutivo, v_0 y parámetro de fricción, ν	44
3.2.2.7. Contracción concéntrica	45
3.3. Simulación de la contracción del músculo vasto intermedio humano . .	48
3.3.0.1. Tensión isométrica máxima, P_0	53
4. Predicción de la contracción del tejido utilizando redes neuronales	55
4.1. Generación de muestras	55
4.2. Entrenamiento de las redes	56
4.3. Predicción en geometrías idealizadas	58
4.3.1. Resultados para el modelo idealizado	58
4.3.2. Resultados para el modelo de geometría fusiforme	65
4.4. Predicción en geometrías reales	68

4.4.1. Resultados para el modelo del músculo vasto intermedio humano	68
5. Conclusiones y líneas futuras	71
5.1. Conclusiones	71
5.2. Líneas futuras	73
6. Bibliografía	75
Lista de Figuras	77
Lista de Tablas	83
Anexos	84
A. Evolución del campo de desplazamientos para el modelo idealizado	87
B. Evolución del campo de desplazamientos para el modelo de geometría fusiforme	89
C. Evolución del campo de desplazamientos para el modelo del músculo vasto intermedio humano	91
D. Código de programación para una red neuronal	93
E. Muestras utilizadas en el entrenamiento de las redes neuronales	97
E.1. Modelo idealizado	97
E.2. Modelo fusiforme	97
E.3. Modelo vasto intermedio	97

Capítulo 1

Introducción

Este capítulo servirá para situar en contexto la temática de este Trabajo Final de Grado. En él, se presenta una breve introducción al tejido muscular así como una descripción más detallada del tejido musculo esquelético. Además, se explican los objetivos establecidos y la estructura de desarrollo de la memoria de este proyecto.

1.1. El tejido muscular

El sistema musculoesquelético está compuesto principalmente de huesos, músculos, tendones y ligamentos que se unen entre ellos para permitir el movimiento y para mantener al esqueleto estable (Pacheco et al., 2019).

En concreto, el tejido muscular está formado por unas células denominadas miocitos o fibras musculares que se superponen unas con otras para permitir la contracción y por tanto el movimiento.

El tejido muscular es un tejido excitable porque responde a estímulos nerviosos, es contráctil porque puede disminuir su longitud, es extensible porque puede estirarse, y es elástico porque las células recuperan su longitud original tras estiramientos o contracciones.

La principal función del tejido muscular es la de permitir la locomoción y el movimiento del cuerpo humano. Esto incluye todo tipo de movimientos tanto voluntarios como involuntarios. Además, debido a que es un tejido que se localiza en múltiples lugares del cuerpo cumple con diferentes funciones:

- Interviene en la contracción de las fibras del corazón, por lo que participa en la circulación de la sangre.
- Genera calor a través de la termogénesis.

- Permite mantener las posiciones corporales, es decir, nos permite estar sentados o estar de pie de manera firme y estable.
- Crea una capa gruesa de tejido muscular y células que recubren a otros órganos y los protege.

Se distinguen tres tipos de tejido muscular según su estructura y función, tal como se muestra en la Figura 1.1.

- **Músculo liso:** Está constituido por células fusiformes, uninucleadas y de control involuntario. Se encuentra en las paredes de los órganos huecos de todo el cuerpo como las paredes de órganos como la vejiga urinaria y el útero, las paredes del tubo digestivo y las paredes arteriales del corazón.
- **Músculo estriado cardíaco:** Está formado por células con un núcleo central y que además presentan estriaciones transversales. Conforman la pared del corazón y su contracción rítmica es involuntaria.
- **Músculo estriado esquelético:** Está compuesto por células con varios núcleos (multinucleadas) largas que se contraen para generar el movimiento. Es el tejido del que se va a profundizar un poco más ya que es el tipo de músculo con el que se trabaja en este Trabajo Fin de Grado




Figura 1.1: Diferentes tipos de músculos

1.2. Músculo estriado esquelético

El músculo estriado esquelético, llamado así por distinguirse estriaciones al ser observado al microscopio, y porque la mayor parte de él se asocia al esqueleto, funciona bajo control voluntario ya que se encuentra inervado por el sistema nervioso somático. Está constituido por largas células multinucleadas, cuyos núcleos se localizan en la periferia. Este tipo muscular se encuentra en la lengua, la faringe, en el segmento superior del esófago y en la porción lumbar del diafragma, además de los músculos extrínsecos del ojo y en toda la musculatura de las extremidades y del tronco (Schünke et al., 2011).

El músculo esquelético está formado por fibras musculares o miocitos, tejido conectivo y vasos sanguíneos. Las fibras musculares se asocian entre sí para formar los fascículos musculares, y éstos a su vez se unen para formar el músculo esquelético, principal responsable de la movilidad. Las fibras musculares están rodeadas por una lámina basal y por fibras reticulares y colágenas que forman el endomisio. Cada fascículo muscular está rodeado por otra envuelta de conectivo denso denominada perimisio y todo el músculo por el epimisio, también tejido conectivo. Por estas envueltas de tejido conectivo penetran y se dispersan los vasos sanguíneos y ramificaciones nerviosas que controlan la contracción muscular. La Figura 1.2 representa la estructura del músculo esquelético.




Figura 1.2: Estructura del tejido músculo esquelético

Además, no todas las fibras musculares son iguales sino que existen unas denominadas de contracción lenta y otras de contracción rápida. Las de contracción lenta actúan en movimientos prolongados y en el mantenimiento de la postura, mientras

que las de contracción rápida actúan en movimientos breves e intensos.

Cada fibra muscular está formada por haces filamentosos, que la recorren en toda su longitud, denominados miofibrillas. Cada miofibrilla está formada por filamentos de miosina (filamentos gruesos) y filamentos de actina (filamentos finos) adyacentes entre sí, que son grandes moléculas proteicas polimerizadas responsables de la contracción muscular (Guythón and Hall, 2011).

A lo largo de las miofibrillas, orientadas transversalmente y a intervalos regulares, se encuentran unas formaciones reticulares de naturaleza proteica, los discos Z. Cuando estos discos se observan lateralmente, aparecen como líneas estrechas, densas y en zig-zag, denominadas líneas Z. La separación entre dos líneas Z consecutivas constituye la unidad funcional contráctil del músculo, el sarcómero. Esta descripción corresponde con la imagen D de la Figura 1.3.




Figura 1.3: Organización del músculo esquelético, desde el nivel macroscópico al nivel molecular

Los filamentos finos se unen a ambos lados de la línea Z y, colocados entre ellos, se sitúan los filamentos gruesos, ocupando la zona central del sarcómero. En la imagen D de la figura 1.3 podemos observar que los filamentos de miosina y de actina se alternan

parcialmente y de esta manera hacen que las miofibrillas tengan bandas claras y oscuras alternas.

La contracción muscular es el resultado de la interacción molecular que se produce entre las proteínas actina y miosina, lo que lleva a un deslizamiento de los filamentos finos sobre los filamento gruesos (Guython and Hall, 2011).




Figura 1.4: Estados relajado y contraído de un sarcómero en la contracción muscular

La Figura 1.4 muestra el estado relajado (superior) y contraído (inferior) de un sarcómero. El desplazamiento de los filamentos finos, anclados en las líneas Z, se produce hacia el centro del sarcómero, aproximando las líneas Z y acortando la longitud sarcomérica. Cuando se produce la contracción, la banda A se mantiene constante, por lo que no modifica su longitud, mientras que las bandas I y H se estrechan.

Como cada miofibrilla está formada por numerosos sarcómeros, el resultado final de la contracción es el acortamiento de las miofibrillas, la fibra muscular y el músculo.

1.3. Objetivos

El objetivo global de este proyecto consiste en desarrollar una metodología computacional que permita predecir el comportamiento del tejido muscular esquelético en tiempo real. Todo esto en base a unos parámetros de entrada, que no son más que algunas variables mecánicas del tejido.

Esta metodología computacional se basa en el método de los elementos finitos y las redes neuronales. Para ello, se simularán una serie de modelos de diversas geometrías tridimensionales mediante el software COMSOL Multiphysics. Estos modelos servirán

de entrenamiento a cada red neuronal, con el objetivo de que las predicciones de las redes se parezcan lo máximo posible al resultado obtenido en el software.

Para la generación de muestras para su futuro entrenamiento en las redes, se utilizara el software COMSOL Multiphysics 5.2a y el software MATLAB R2017b.

Para entrenar y desarrollar las redes neuronales, se ha usado el entorno de Google Colab.

Para conseguir este objetivo global se plantean una serie de objetivos parciales:

- Estudio del modelo de comportamiento del tejido muscular y su implementación en COMSOL.
- Estudio de diversas geometrías tridimensionales, pasando por modelos idealizados hasta llegar a un modelo real, para poder llevar a cabo la simulación de la contracción muscular.
- Análisis de la respuesta de los diferentes modelos a la variación de determinados parámetros.
- Generación de poblaciones de modelos para su uso posterior en el entrenamiento de las redes neuronales.
- Programación de las redes neuronales en Python con la herramienta Google Colab y posterior análisis de los resultados obtenidos para valorar el uso de las redes neuronales en la simulación del tejido musculo-esquelético.

1.4. Descripción de la memoria

La estructura que se llevará a cabo en esta memoria será la siguiente:

- **Capítulo uno:** un primer capítulo introductorio en el que se explicará brevemente el tejido muscular así como sus funciones y más en profundidad el tejido músculo esquelético. Además de incluir los objetivos de este Trabajo Final de Grado.
- **Capítulo dos:** en el segundo capítulo se aborda el tema de las redes neuronales, explicando en qué consiste la inteligencia artificial, el aprendizaje profundo o “Deep Learning” y más en profundidad las redes neuronales.

- **Capítulo tres:** un tercer capítulo donde, por un lado se detallan los fundamentos teóricos del comportamiento del tejido músculo esquelético, y por otro se describen, para cada modelo, la geometría, variables y parámetros característicos, la malla y las condiciones de contorno establecidas. Además, en este capítulo también se incluye las simulaciones de los distintos modelos y los resultados obtenidos, mostrando gráficas para una mejor comprensión de estos.
- **Capítulo cuatro:** en este capítulo se describe la predicción de la contracción muscular para los distintos modelos utilizando redes neuronales, comenzando por la generación de las muestras, pasando por el entrenamiento de las redes y finalizando por sus resultados y validaciones. Además se añaden tanto datos como gráficas para una mejor comprensión.
- **Capítulo quinto:** el quinto capítulo hace referencia a las conclusiones y futuras líneas de investigación a partir de este proyecto.
- **Anexos:** este último capítulo se redacta con el fin de complementar y completar los capítulos anteriores incluyendo para ello representaciones de la contracción muscular, el código de programación utilizado para el entrenamiento de las redes neuronales y la generación de muestras empleadas en el entrenamiento de las redes.

Capítulo 2

Aprendizaje Profundo (*Deep Learning*) y Redes Neuronales

En este capítulo, se pretenden explicar de manera simple y clara los fundamentos teóricos en los que se basa el desarrollo de este TFG. Para situar el ámbito de estudio de este TFG, se va a explicar brevemente los conceptos de Inteligencia Artificial y de Aprendizaje Profundo. Además, se profundizará en la técnica de redes neuronales, metodología que se utilizará en este proyecto para predecir el comportamiento del tejido muscular esquelético. Conoceremos qué son las redes neuronales, cómo se estructuran así como su funcionamiento. Finalmente, se comentará algunos posibles usos de las redes neuronales, los cuales ya están implementadas en nuestro entorno.

2.1. La Inteligencia Artificial

Durante los últimos años la Inteligencia Artificial (IA) se ha convertido en un campo de interés tanto dentro como fuera de la comunidad científica. En 1956 un grupo de informáticos (Moor, 2006) propuso que los ordenadores podían programarse para pensar y razonar por sí mismos ya que cada aspecto del aprendizaje o cualquier otra característica de la inteligencia puede describirse con la precisión suficiente para que una máquina sea capaz de simularla.

Por lo tanto, la IA se puede definir como la introducción de la inteligencia humana a las máquinas, de manera que éstas puedan tomar decisiones sin ayuda del ser humano. Esta inteligencia se programa explícitamente, con una lista de reglas que tienen en cuenta todas las combinaciones posibles que toman parte en el proceso de un problema particular.

2.1.1. Aplicaciones de la Inteligencia Artificial

En la actualidad, existen numerosas aplicaciones de los sistemas de IA en nuestro entorno. A continuación se muestran algunos de los ejemplos más comunes (IBM Cloud Education, 2021).

- **Reconocimiento de voz:** también se conoce como reconocimiento automático de voz (ASR) o conversión de voz a texto, y es una capacidad que utiliza el procesamiento del lenguaje natural (NLP) para procesar el habla humana en un formato escrito. Muchos dispositivos móviles incorporan el reconocimiento de voz en sus sistemas para realizar búsquedas por voz, como por ejemplo buscadores de Google o los asistentes inteligentes Siri y Alexa.
- **Servicio al cliente:** un ejemplo de esta aplicación son los chatbots en línea que responden preguntas frecuentes (FAQ) sobre temas, como el envío, o brindan asesoramiento personalizado, productos de venta cruzada o sugerencias de productos para los usuarios. Estos chatbots también se pueden encontrar en aplicaciones de mensajería, como Telegram y Facebook Messenger.
- **Visión por computadora:** esta tecnología de inteligencia artificial permite que las computadoras y los sistemas obtengan información significativa a partir de imágenes digitales, videos y otras entradas visuales, y en función de esas entradas, puede tomar medidas. Impulsada por redes neuronales convolucionales, la visión por computadora tiene aplicaciones dentro del etiquetado de fotos en las redes sociales, imágenes de radiología en el cuidado de la salud y automóviles autónomos dentro de la industria automotriz.
- **Recomendaciones personalizadas:** utilizando datos de comportamiento de consumo anteriores, los algoritmos de inteligencia artificial pueden ayudar a descubrir tendencias de datos que se pueden utilizar para desarrollar estrategias de venta cruzada más efectivas. Esto se utiliza para hacer recomendaciones complementarias al cliente a la hora de comprar un producto así como sugerencias de visualización en plataformas como YouTube.

2.2. Aprendizaje Automático (*Machine Learning*) y Aprendizaje Profundo (*Deep Learning*)

En su forma más simple, la inteligencia artificial es un campo que combina la informática y conjuntos de datos sólidos para permitir la resolución de problemas. Posee algunos subcampos como el aprendizaje automático (*Machine Learning*) y el aprendizaje profundo (*Deep Learning*), que se mencionan con frecuencia junto con la inteligencia artificial. Estas disciplinas crean sistemas que hacen predicciones o clasificaciones basadas en datos de entrada (IBM Cloud Education, 2021).

Dado que el aprendizaje profundo y el aprendizaje automático tienden a usarse indistintamente, vale la pena señalar los matices entre los dos. Como se mencionó anteriormente, tanto el aprendizaje profundo (*Deep Learning*) como el aprendizaje automático (*Machine Learning*) son subcampos de la inteligencia artificial, y el aprendizaje profundo es en realidad un subcampo del aprendizaje automático, tal como se visualiza en la Figura 2.1.




Figura 2.1: Diferencias entre Inteligencia Artificial, Aprendizaje Automático y Aprendizaje Profundo.

El aprendizaje automático se refiere a los diferentes métodos a través de los cuáles una máquina puede aprender por sí misma; el aprendizaje profundo no es más que uno de esos métodos.

Por ello, se puede decir que el aprendizaje profundo es una técnica del aprendizaje automático. Dicha técnica se basa en el uso de redes neuronales que están formadas por un gran número de capas y que son capaces de realizar tareas complejas.

2.2.1. Ejemplo de aplicación sencilla de ambas técnicas

Por ejemplo, imaginemos una máquina dotada con *Machine Learning* que está programada para identificar imágenes de perros. A través de códigos y algoritmos, esta máquina sería capaz de identificar imágenes de perros una vez que se le ha facilitado la imagen de un perro. Para ello, la máquina debe aprender a tratar con diferentes características visuales que diferencian a los perros de otros animales, para poder identificar a un perro por sí misma.

Si aplicamos esto al *Deep learning*, la máquina funcionaría como una red neuronal en la que la información pasaría por diferentes capas jerárquicas. En la primera capa, la red procesa información muy simple. Esta información pasa a la segunda capa, donde profundiza un poco más. De esta a la tercera capa, donde la información será todavía más compleja, y así sucesivamente.

Si extrapolamos esto al ejemplo del perro, la primera capa podría detectar los bordes de la imagen. La segunda, las zonas más claras u oscuras. La tercera detecta formas simples. La cuarta formas más complejas. La quinta podría combinar estas formas para dar lugar a caras, colas o patas. Y así sucesivamente hasta llegar al nivel jerárquico superior, en el cual la máquina ya habrá aprendido a identificar imágenes de perros.

En este caso, el *Deep learning* permite identificar la imagen del perro con menos datos de entrada. Por ejemplo no hace falta que las imágenes tuvieran la etiqueta “perro”, mientras que en el *Machine learning* hace falta una serie de distinciones.

De este ejemplo también se puede extraer que la principal diferencia entre el *Deep learning* y el *Machine learning* es la cantidad de transformaciones que se aplican a los datos desde la capa de entrada a la de salida, lo cual permite procesar la información de forma más compleja y profunda.

2.3. Aprendizaje Profundo (*Deep Learning*) y Redes Neuronales

2.3.1. Aprendizaje profundo

Una vez explicado brevemente las características sobre el aprendizaje automático y el aprendizaje profundo, profundizaremos en este último y en concreto sobre su técnica mediante redes neuronales.

El aprendizaje profundo consiste en un aprendizaje estructurado por capas, que emplea redes neuronales artificiales para emular la manera de aprender de los seres humanos. Estas redes están organizadas jerárquicamente, de manera que se realizan procesamiento de información cada vez más profundos. Gracias a la información de entrada, las máquinas dotadas con deep learning son capaces de aprender por sí mismas, sin necesidad de introducir unas reglas o instrucciones previas (Iat, 2021).

2.3.2. Redes neuronales

¿Y qué son las redes neuronales?

Una red neuronal es un modelo simplificado que emula el modo en que el cerebro humano procesa la información. Esta formada por un conjunto de neuronas artificiales que están conectadas y transmiten señales entre sí. Estas señales se transmiten desde la entrada hasta generar una salida (Kriegeskorte and Golan, 2019; Gavrilova, 2020).

El objetivo principal de las redes neuronales es aprender modificándose automáticamente a sí mismas de forma que pueden llegar a realizar tareas complejas que no podrían ser realizadas mediante la programación clásica. De esta forma se pueden automatizar funciones que en un principio sólo podrían ser realizadas por personas.

Las redes neuronales están formadas por 3 o más capas entrelazadas que procesan la información como se muestra en la Figura 2.2.




Figura 2.2: Estructura de las redes neuronales

Dichas capas son:

- **Capa de entrada o Input Layer:** es aquella que recibe los datos de entrada.
- **Capa oculta o Hidden Layer:** son las capas de neuronas que realizan el procesamiento de información desde niveles más abstractos a más concretos. Cuantas más neuronas formen esta capa, más complejos serán los cálculos que se podrán realizar.
- **Capa de salida o Output Layer:** son aquellas que muestran la predicción final de la red.

2.3.2.1. Funcionamiento de las redes neuronales

Como se ha mencionado anteriormente, el funcionamiento de las redes se asemeja al del cerebro humano.

Las redes reciben una serie de valores de entrada y cada una de estas entradas llega a un nodo llamado neurona. Las neuronas de la red están a su vez agrupadas en capas que forman la red neuronal. Cada una de las neuronas de la red posee a su vez un peso. Los pesos son coeficientes que pueden ajustarse dentro de la red y determinan la intensidad de la señal de entrada registrada por la neurona. A mayor peso, más importancia tiene esa señal. Cada capa de neuronas calculará una pequeña función y la información conseguida se transmitirá hasta la siguiente capa y así sucesivamente hasta llegar al final de la red. Este funcionamiento puede observarse de forma esquemática en la Figura 2.3 (Gavrilova, 2020).




Figura 2.3: Esquema de funcionamiento de una red neuronal

Una vez que se ha alcanzado el final de la red se obtiene una salida que será la predicción calculada por la red. Cuantas más capas posea la red y más compleja sea, también serán mas complejas las funciones que pueda realizar.

2.3.2.2. Entrenamiento de las redes neuronales

Al principio, todas las ponderaciones (pesos) son aleatorias y las respuestas que resultan de la red son, posiblemente, disparatadas. Para conseguir que la red neuronal realice las funciones deseadas, es necesario entrenarla.

El entrenamiento de una red neuronal se realiza modificando los pesos de sus neuronas para que consiga extraer los resultados deseados. Para ello, continuamente se presentan a la red ejemplos para los que se conoce el resultado, y las respuestas que proporciona se comparan con los resultados conocidos. En función del resultado que se obtenga, se modifican los pesos de las neuronas para corregir el error cometido y obtener el resultado deseado. Este método es conocido como *Backpropagation* o propagación hacia atrás (Kriegeskorte and Golan, 2019).

Este proceso se repite muchas veces y a medida que progresa el entrenamiento, la red se va haciendo cada vez más precisa en la replicación de resultados conocidos. Una vez entrenada, la red se puede aplicar a casos futuros en los que se desconoce el resultado.

2.3.2.3. Funciones y aplicación de las redes neuronales

Pese a que en la actualidad se ha popularizado su uso, las redes neuronales existen desde la década de 1950. Sin embargo, la poca potencia de los equipos de aquella época y la inexistencia de algoritmos que permitiesen a las redes aprender de forma eficiente provocó que estas dejaran de usarse. Ha sido posteriormente, gracias a la creación del algoritmo de *Backpropagation*, al uso de GPUs (*Graphics processing units*), que permiten realizar grandes optimizaciones para este tipo de cálculos, y al mayor número de datos disponibles para entrenamiento, cuando las redes neuronales han vuelto a resurgir.

El alcance de las redes neuronales es muy amplio, debido a su funcionamiento, son capaces de aproximar cualquier función existente con el suficiente entrenamiento. Principalmente las redes neuronales son utilizadas para tareas de predicción y clasificación (iat, 2021).

Su rango de actuación es amplio y de gran utilidad hoy en día, no solo se utilizan para aplicaciones de Industria 4.0, como por ejemplo en reconocimiento de piezas y defectos que no han sido introducidos previamente, si no que son utilizados en otras áreas como la economía, en la que pueden ayudar a predecir cuanto van a variar los precios a lo largo de los años, o incluso en medicina donde son de gran ayuda para diagnosticar diversos problemas de salud.

Las redes neuronales se han convertido en una pieza clave para el desarrollo de la Inteligencia Artificial, es uno de los principales campos de investigación y el que más está evolucionando con el tiempo, ofreciendo cada vez soluciones más complejas y eficientes.

Capítulo 3

Simulación computacional del tejido músculo-esquelético

En este capítulo se explicará la formulación utilizada para simular el comportamiento mecánico del tejido músculo-esquelético y la descripción de los distintos modelos utilizados, desde su geometría hasta el tipo de malla empleada. Además, se incluye la simulación de los modelos considerando la variación de distintas parámetros que definen su comportamiento analizando cómo influyen estas en la contracción del músculo.

3.1. Modelado del tejido músculo-esquelético

En este apartado se resume el modelo de comportamiento del tejido músculo-esquelético utilizado en este TFG. Este modelo fue desarrollado previamente dentro del grupo de investigación *Applied Mechanics and Bioengineering* (AMB) del Instituto de Investigación en Ingeniería de Aragón (I3A). Una descripción más completa puede encontrarse en los trabajos de Grasa et al. (2011) y Hernández-Gascón et al. (2013). El modelo es capaz de reproducir tanto la respuesta activa como pasiva del tejido y se basa en la definición de una función densidad de energía de deformación que define el comportamiento hiperelástico anisótropo del tejido (Hernández-Gascón et al., 2013):

$$\Psi = \Psi(\mathbf{C}, \mathbf{C}_e, \lambda_a, \mathbf{N}, \mathbf{M}) \quad (3.1)$$

Esta función depende de las variables de estado, \mathbf{F} (gradiente de deformación) a través de $\mathbf{C} = \mathbf{F}^T \mathbf{F}$ (tensor de deformación de Cauchy-Green por la derecha), λ_a (contracción o elongación de las fibras musculares) y de los tensores estructurales

$\mathbf{M} = \mathbf{m}_0 \otimes \mathbf{m}_0$ y $\mathbf{N} = \mathbf{n}_0 \otimes \mathbf{n}_0$, que definen la anisotropía del músculo debida a la dirección preferencial de las fibras musculares y de colágeno, respectivamente. A su vez, la función depende también de \mathbf{C}_e , que representa la deformación elástica de los puentes cruzados que se establecen entre los filamentos de actina y miosina. La función de energía de deformación puede dividirse en dos partes, una que contempla la energía cuando se produce cambio de volumen y otra asociada a la deformación a volumen constante, llamada desviadora; este tratamiento permite gestionar computacionalmente la restricción de cuasi-incomprensibilidad. Además, la parte desviadora, se divide en una contribución pasiva, debida al colágeno y la elastina, $\bar{\Psi}_p$, y una contribución activa asociada a las fibras musculares $\bar{\Psi}_a$. Por consiguiente, la función energía de deformación total Ψ puede expresarse como:

$$\Psi = \Psi_{vol}(J) + \bar{\Psi}_p(\bar{\mathbf{C}}, \mathbf{N}) + \bar{\Psi}_a(\bar{\mathbf{C}}_e, \bar{\lambda}_a, \mathbf{M}) \quad (3.2)$$

Donde $J = \det \mathbf{F} > 0$ es el jacobiano y con la descomposición multiplicativa del gradiente de deformación en una parte volumétrica y otra desviadora $\mathbf{F} = J^{1/3} \bar{\mathbf{F}}$ se obtienen las expresiones $\bar{\mathbf{C}} = J^{-2/3} \mathbf{C}$. A su vez, la parte desviadora del gradiente de deformación se descompone en $\bar{\mathbf{F}} = \bar{\mathbf{F}}_e \bar{\mathbf{F}}_a$. Siendo $\bar{\mathbf{F}}_a$ la deformación asociada a la contracción y $\bar{\mathbf{F}}_e$ la deformación elástica de los puentes cruzados y que permite definir el tensor $\bar{\mathbf{C}}_e$. Finalmente $\bar{\lambda}_a$ representa el alargamiento isocórico del tejido. La Eq. (3.2) se puede particularizar para el músculo esquelético (Hernández-Gascón et al., 2013) y formularse a través de los invariantes de los distintos tensores como:

$$\Psi = \Psi_{vol}(J) + \bar{\Psi}_p(\bar{I}_1, \bar{I}_2, \bar{I}_4) + f_\lambda f_V f_{train} \bar{\Psi}'_a(\bar{J}_4) \quad (3.3)$$

A continuación se describen en detalle cada uno de los términos de esta expresión.

3.1.1. Comportamiento pasivo

La función de energía de deformación pasiva, $\bar{\Psi}_p$, se define como una función de los invariantes:

$$\bar{I}_1 = tr \bar{\mathbf{C}}, \quad \bar{I}_2 = \frac{1}{2} \left((tr \bar{\mathbf{C}})^2 - tr \bar{\mathbf{C}}^2 \right), \quad \bar{I}_4 = \mathbf{n}_0 \cdot \bar{\mathbf{C}} \mathbf{n}_0 = \bar{\lambda}^2 \quad (3.4)$$

donde \bar{I}_1 and \bar{I}_2 son el primer y segundo invariante del tensor de deformación simétrico de Cauchy-Green modificado $\bar{\mathbf{C}}$, e \bar{I}_4 es el pseudo-invariante relativo a la anisotropía de la respuesta pasiva (fibras de colágeno). De acuerdo con la función de energía de

deformación propuesta por Calvo et al. (2010), la respuesta pasiva $\bar{\Psi}_p$ puede escribirse como:

$$\bar{\Psi}_p = c_1(\bar{I}_1 - 3) + \frac{c_3}{c_4}(\exp^{c_4(\bar{I}_4 - \bar{I}_{40})} - c_4(\bar{I}_4 - \bar{I}_{40}) - 1) \quad (3.5)$$

3.1.2. Comportamiento activo

La energía de deformación asociada a la respuesta activa y en consecuencia, a la interacción de la actina y la miosina, se expresa como el producto de una serie de funciones que escalan la máxima tensión isométrica capaz de generar el músculo. La contribución activa de la función de energía de deformación $\bar{\Psi}'_a$ se expresa en términos del pseudo-invariante asociado a $\bar{\mathbf{C}}_e$ y la dirección \mathbf{m}_0 (Hernández-Gascón et al., 2013):

$$\bar{\Psi}'_a = \frac{1}{2}P_0(\bar{J}_4 - 1)^2 \quad \bar{J}_4 = \mathbf{m}_0 \cdot \bar{\mathbf{C}}_e \mathbf{m}_0 = \bar{\lambda}_e^2 \quad (3.6)$$

donde P_0 es un factor de proporcionalidad relativo a la máxima tensión activa debida a la contracción muscular. La influencia de la superposición de filamentos en la respuesta activa del músculo f_λ es formulada en términos de la elongación de las fibras de los mismos:

$$f_\lambda = \exp \frac{-(\bar{\lambda}_a - \lambda_{opt})^2}{2\xi^2} \quad (3.7)$$

Como se indicó anteriormente $\bar{\lambda}_a$ representa la parte desviadora de la elongación de las fibras musculares. λ_{opt} define la elongación de la fibra a la cual la superposición de los filamentos es óptima para la generación de fuerza y ξ ajusta la amplitud horizontal de la función.

f_V representa la dependencia de la deformación activa con la amplitud de la señal de excitación y se expresa como (Ramírez et al., 2010):

$$f_V = 1 - \exp \frac{a-V}{d} \quad (3.8)$$

donde V es la amplitud del voltaje del estímulo eléctrico, a es el valor de voltaje para el cual no se obtiene respuesta de fuerza y d controla la curvatura de la función.

La fuerza ejercida por un músculo es mayor cuando el tiempo de contracción es más largo y éste puede alcanzar la tetanización completa. Esta dependencia se expresa con f_{train} (Ramírez et al., 2010):

$$f_{train} = (1 - re^{-fr \cdot c}) \sum_{i=1}^n P \frac{t - t_{stim}(i)}{T_c} e^{(1 - \frac{t - t_{stim}(i)}{T_c})} \quad (3.9)$$

donde r y c regulan la curvatura de la pendiente inicial y final de la relación fuerza-frecuencia, con fr la frecuencia del estímulo. n es el número de pulsos de la señal de activación, P y T_c definen la amplitud y el tiempo de contracción aparente de todo el músculo, respectivamente, ante un único pulso y $t_{stim}(i)$ es el intervalo de tiempo entre los estímulos $(i - 1)$ e i .

Con la finalidad de reducir el coste computacional que implica la Eq. (3.9), se propone la siguiente expresión para f_{train} :

$$f_{train} = (\tanh^2(s_1(t - t_i)) \tanh^2(s_2(t - (t_i + t_s)))) \quad (3.10)$$

donde s_1 and s_2 controlan la pendiente inicial y final de la función y t es el tiempo de la simulación. t_i y t_s definen el inicio de la activación y la duración del estímulo, respectivamente.

Finalmente, debe satisfacerse una relación constitutiva derivada de principios termodinámicos para obtener la evolución de la velocidad de contracción $\dot{\bar{\lambda}}_a$ (Hernández-Gascón et al., 2013):

$$P_a - \frac{\partial \bar{\Psi}}{\partial \bar{\lambda}_a} + \left(2\bar{\mathbf{C}}_e \frac{\partial \bar{\Psi}}{\partial \bar{\mathbf{C}}_e} \bar{\mathbf{F}}_a^{-T} \right) : \frac{\partial \bar{\mathbf{F}}_a}{\partial \bar{\lambda}_a} = C \dot{\bar{\lambda}}_a \quad (3.11)$$

donde se define la tensión activa P_a como:

$$P_a = P_0 f(\bar{\lambda}_a) f_{train} f(\dot{\bar{\lambda}}_a) \quad (3.12)$$

Esta expresión tiene en cuenta la dependencia de la tensión activa respecto a la velocidad de contracción. Así, $f(\dot{\bar{\lambda}}_a)$ será:

$$f(\dot{\bar{\lambda}}_a) = \frac{1}{\nu} \dot{\bar{\lambda}}_a + 1 \quad (3.13)$$

donde ν representa el valor absoluto de la máxima velocidad concéntrica de contracción.

El parámetro C se define como:

$$C = \left(\frac{1}{v_0} (P - P_0 f(\bar{\lambda}_a) f_{train}) \right)^2 \quad (3.14)$$

donde P es la tensión total en la fibra muscular. Sustituyendo las Eqs. (3.12) y (3.14) en (3.11), resulta la expresión de $\dot{\bar{\lambda}}_a$ (Grasa et al., 2016) que define la evolución de la velocidad de contracción:

$$\dot{\bar{\lambda}}_a = \frac{P_0 f(\bar{\lambda}_a) f_{\text{train}} - \frac{\partial \bar{\Psi}}{\partial \bar{\lambda}_a} + \left(2 \bar{\mathbf{C}}_e \frac{\partial \bar{\Psi}}{\partial \bar{\mathbf{C}}_e} \bar{\mathbf{F}}_a^{-T} \right) : \frac{\partial \bar{\mathbf{F}}_a}{\partial \bar{\lambda}_a}}{\left(\frac{1}{v_0} (P - P_0 f(\bar{\lambda}_a) f_{\text{train}}) \right)^2 - \frac{1}{\nu} P_0 f(\bar{\lambda}_a) f_{\text{train}}} \quad (3.15)$$

3.2. Simulación de geometrías idealizadas

A continuación, se describen los modelos de elementos finitos usados para simular la contracción del tejido muscular esquelético en el programa COMSOL Multiphysics. Para ello, se han utilizado tres modelos: un modelo idealizado, un modelo de geometría fusiforme y un modelo del músculo vasto intermedio humano, todos en 3D. Con estos modelos se pretende conocer inicialmente cuál es la influencia de los parámetros del modelo en la respuesta del tejido.

3.2.1. Modelo idealizado

En este caso, la geometría consiste en un paralelepípedo rectangular cuyas dimensiones son $a = 10$ mm de ancho, $b = 10$ mm de profundidad, y $L = 100$ mm de altura. Esta geometría del modelo que se muestra en la Figura 3.1 representa en realidad un octavo del bloque completo pues se aplicarán condiciones de simetría en tres planos.




Figura 3.1: Geometría del modelo idealizado.

Para estudiar los fenómenos que se producen durante la contracción del músculo y poder definir adecuadamente el modelo, se han empleado los siguientes módulos del programa:

- “Mecánica de sólidos”, que permite introducir el modelo de comportamiento del tejido.
- “Coordenadas curvilíneas”, que hace posible la definición de la anisotropía del tejido estableciendo la dirección de las fibras musculares en la geometría. Se ha supuesto que la dirección de la contracción coincide con la dirección de comportamiento pasivo con lo que $\mathbf{n}_0 = \mathbf{m}_0$ (Eqs. (3.4) y (3.6))
- “Ecuación en derivadas parciales en forma general”, que permite resolver la evolución de $\dot{\bar{\lambda}}_a = \frac{d\lambda_a}{dt}$ descrita en la Eq. (3.15).

La Tabla 3.1 recoge el valor de los diferentes parámetros utilizados en el modelo tomados de trabajos previos (Calvo et al., 2010; Hernández-Gascón et al., 2013; Grasa et al., 2016)

Parámetro	Valor	Descripción
ρ	1000 kg/m ³	Densidad del tejido muscular
β_A	0 rad	Ángulo de \mathbf{n}_0 respecto al eje Z
c_1	8,837 kPa	Parámetro del comportamiento pasivo
c_3	9,877 kPa	Parámetro del comportamiento pasivo
c_4	2,238	Parámetro del comportamiento pasivo
\bar{I}_{40}	1,25	Parámetro del comportamiento pasivo
κ	$1 \cdot 10^9$ Pa	Bulk modulus
t_i	0 s	Tiempo inicial de contracción
t_s	0.9 s	Duración de la contracción
s_1	10	Pendiente inicial de la función de activación
s_2	10	Pendiente final de la función de activación
λ_{opt}	1	Alargamiento óptimo
ξ	0,16384	Controla la relación fuerza-alargamiento

Tabla 3.1: Parámetros utilizados en el modelo idealizado.

Con este modelo se pretende analizar cómo influyen una serie de parámetros, que se recogen en la Tabla 3.2, en la contracción del músculo. Para ello, se estudiará el desplazamiento que se produce en el extremo superior del modelo durante este proceso.

Parámetro	Valor mínimo	Valor máximo	Descripción
P_0	1 kPa	100 kPa	Tensión isométrica máxima
ν_0	1	20	Parámetro constitutivo
a	5 mm	15 mm	Anchura
b	5 mm	15 mm	Profundidad
ν	0,2	0,7	Parámetro de fricción
F_{ext}	1 N	80 N	Carga externa

Tabla 3.2: Rangos de variación de los parámetros del modelo idealizado utilizados en el estudio

Sobre el modelo se aplica simetría en X e Y en las caras posteriores del paralelepípedo y simetría en Z en la base inferior del mismo. En consecuencia, el desplazamiento en dichas superficies en la dirección de su normal es nulo. Los planos en los que se aplican estas condiciones se muestran en la Figura 3.2.




Figura 3.2: Condiciones de simetría del modelo idealizado.

Además, es necesario definir la orientación de las fibras musculares, que para este modelo son paralelas a la dirección Z global, tal como se visualiza en la Figura 3.3.




Figura 3.3: Orientación de las fibras musculares del modelo idealizado.

Finalmente, en cuanto al mallado del modelo, se lleva a cabo un análisis de la sensibilidad del tamaño de la malla para poder elegir aquella que muestre resultados de manera óptima con un coste computacional reducido. El número de nudos y elementos de las diferentes mallas se muestra en la Tabla 3.3. La Figura 3.4 muestras las diferentes mallas analizadas.

Descripción de la malla	Nº de nodos	Elementos
Malla extremadamente fina	1836	1250
Malla extra fina	480	261
Malla fina	126	52
Malla normal	44	10
Malla gruesa	32	7
Malla extremadamente gruesa	12	2

Tabla 3.3: Tamaños de malla analizados para el modelo idealizado.




Figura 3.4: Mallas analizadas para el modelo idealizado.

De este modo, se estudió el desplazamiento del paralelepípedo para distintos tamaños de malla, manteniendo constantes el resto de parámetros. Como se observa en la Figura 3.5, la solución es prácticamente insensible al tamaño de la malla, por lo que se utiliza una malla simple con pocos elementos, como es el caso de la malla normal, para optimizar los tiempos de simulación. Esta malla se utilizará en todos los casos de estudio de este modelo.




Figura 3.5: Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo para los distintos tamaños de malla.

Una vez descrito el modelo empleado, se procede a estudiar como afecta la variación de cada variable, descritas en la Tabla 3.2, en la contracción del músculo. Dichos parámetros, oscilaran entre un valor mínimo y un valor máximo.

3.2.1.1. Tensión isométrica máxima, P_0

En primer lugar, se analiza cómo afecta el cambio de la tensión isométrica máxima en la contracción del músculo. Para ello, se utiliza el programa COMSOL para obtener el desplazamiento en los distintos instantes de tiempo y se grafica la solución con el software MATLAB.

Para eso, se simulará la contracción del musculo variando este parámetro entre 1 [kPa] y 100 [kPa], tal como figura en la Tabla 3.2, y dejando fijos el resto de parámetros. La solución obtenida en un punto situado en el extremo superior del modelo con respecto al tiempo se muestra en la Figura 3.6.




Figura 3.6: Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo para distintos valores de P_0 .

Como se puede observar en la Figura 3.6, si se aumenta la tensión isométrica se consigue un mayor desplazamiento, lo que se traduce en una mayor contracción del músculo.

En el Anexo A se muestra con detalle el mapa de color para la contracción del músculo en los distintos instantes de tiempo para un valor de 90 [kPa] de tensión isométrica.

3.2.1.2. Parámetro constitutivo, v_0

Para estudiar como influye el parámetro v_0 en la contracción muscular, se procede de la misma manera que el caso anterior. Se simula el modelo variando el parámetro v_0 entre el rango establecido en la Tabla 3.2 y el resto de parámetros permanecen fijos.

Como se aprecia en la Figura 3.7, el parámetro v_0 influye en el tiempo de contracción del músculo. Conforme mayor es este parámetro, antes se produce la contracción del músculo.




Figura 3.7: Resultados del desplazamiento del extremo del paralelepípedo considerando cinco valores del parámetro v_0 .

3.2.1.3. Dimensiones características

En este caso, se analiza cómo se comporta el tejido cuando se modifica parte de su geometría. Para ello, se varían los parámetros a y b , correspondientes a la anchura y profundidad del paralelepípedo respectivamente, entre 5 [mm] y 15 [mm].

La Figura 3.8 muestra el desplazamiento que se produce a lo largo del tiempo al variar los parámetros de anchura y profundidad del modelo. Como se puede observar, prácticamente sólo se aprecia una línea cuando debería haber 5, ya que hay 5 parejas de valores distintos. Por lo que se llega a la conclusión que la variación de dichos parámetros no influye en la contracción del músculo pues está gobernada por el valor de la tensión isométrica máxima.




Figura 3.8: Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo considerando cinco combinaciones de la sección transversal para el modelo idealizado.

3.2.1.4. Parámetro de fricción, ν

Otra variable que se analiza es el parámetro ν , cuyo valor oscilara entre 0,2 y 0,7, tal como queda reflejado en la Tabla 3.2. La Figura 3.9 muestra la influencia de este parámetro sobre la evolución del desplazamiento a lo largo del tiempo.

Como se puede observar en la Figura 3.9, el parámetro ν influye en la capacidad de contracción del músculo. Es decir, si aumentamos dicho parámetro se consigue un mayor desplazamiento del extremo del músculo.




Figura 3.9: Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo para distintos valores de ν .

3.2.1.5. Tensión isométrica máxima, P_0 y parámetro constitutivo, v_0

Después de analizar cada variable individualmente, se estudia como afecta la combinación de algunas variables en la contracción del músculo. En primer lugar, se examina la pareja de variables P_0 y v_0 . Para ello, se simulará la contracción del musculo variando el parámetro de tensión isométrica entre 1 [kPa] y 100 [kPa] y el parámetro constitutivo entre 1 y 20, tal como figura en la Tabla 3.2, y dejando fijos el resto de parámetros. La solución obtenida en un punto situado en el extremo superior del modelo con respecto al tiempo es la Figura 3.10.

La Figura 3.10 muestra el desplazamiento que se produce para distintos valores de P_0 y v_0 . En ella se observa que cuanto mayor es la tensión isométrica aplicada, mayor desplazamiento se consigue. Mientras que el parámetro constitutivo, v_0 , influye en el tiempo de contracción del músculo. Conforme mayor es este parámetro, antes se contrae el músculo.




Figura 3.10: Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo considerando cinco combinaciones de los parámetros P_0 y v_0 para el modelo idealizado.

3.2.1.6. Parámetro constitutivo, v_0 y parámetro de fricción, ν

Otra pareja de parámetros a analizar son la formada por el parámetro de fricción, ν , y el parámetro constitutivo, v_0 . Se procede de la misma manera que en los casos anteriores. Esta vez se varía el parámetro ν entre 0,2 y 0,7 y el parámetro v_0 entre 1 y 20. Su curva de desplazamiento frente a tiempo es la mostrada en la Figura 3.11.

En la Figura 3.11 se observa que cuanto más pequeño es el parámetro v_0 , más le cuesta al músculo contraerse. Mientras que si aumentamos el parámetro de fricción, ν , se consigue un desplazamiento mayor, es decir se contrae más el músculo.




Figura 3.11: Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo considerando cinco combinaciones de los parámetros v_0 y ν para el modelo idealizado.

3.2.1.7. Contracción concéntrica

Una vez analizada la influencia de los parámetros de la Tabla 3.2, se estudia la velocidad a la que se contrae el músculo al aplicarle una carga en el extremo. Para ello se realizan ciertas modificaciones en el modelo.

En cuanto a la geometría, se coloca el paralelepípedo en contacto sobre un cubo de 20 [mm] de lado, que actuará como soporte fijo. La nueva configuración del modelo se muestra en la Figura 3.12.




Figura 3.12: Geometría del modelo idealizado para el cálculo de la contracción concéntrica.

Con respecto a las físicas que intervienen, se mantienen los mismos módulos físicos empleados. En esa configuración y bajo el efecto de la carga exterior, se analizará la velocidad [m/s] a la que se contrae el músculo. Para ello se utiliza una sonda en uno de los extremos inferiores del modelo.

En cuanto a las condiciones de contorno, se modifican y cambian algunas de las explicadas anteriormente. Por lo que estas quedan de la siguiente manera:

- Se aplica simetría en X e Y en las caras delanteras del paralelepípedo y en las caras delanteras del bloque fijo. Además, se impone simetría en Z en la base superior del paralelepípedo y en la base inferior del bloque. En consecuencia, el desplazamiento en la dirección normal de dichas superficies es nulo. Estas condiciones quedan representadas en la Figura 3.13.




Figura 3.13: Condiciones de simetría del modelo idealizado para el cálculo de la contracción concéntrica.

- Se define una condición de contacto entre la cara superior del bloque y la base inferior del paralelepípedo, tal como se refleja en la Figura 3.14. Se utilizará para ello el método de penalización, para el cual se establecen un parámetro de rigidez característica y un factor de penalización de la presión de contacto.




Figura 3.14: Condición de contacto del modelo idealizado para el cálculo de la contracción concéntrica.

- Se define una carga actuando sobre la base inferior del paralelepípedo en la dirección $-Z$ que se hará variar entre 1 y 80 [N]. Dicha condición se representa en la Figura 3.15.




Figura 3.15: Carga aplicada en el modelo idealizado para el cálculo de la contracción concéntrica.

Finalmente, en cuanto al mallado del modelo, se utiliza un tamaño de malla normal ya que se ha comprobado con los estudios anteriores realizados, que se obtienen datos precisos y tiene un coste computacional óptimo.

Una vez descrito el modelo empleado, se estudia cómo varía la velocidad a la que se contrae el músculo al aplicarle distintos valores de carga en el extremo. Para ello, se utiliza el programa COMSOL y se obtiene la velocidad de contracción en los distintos instantes de tiempo y se selecciona el valor máximo. Posteriormente, se grafica la solución con el software MATLAB. La gráfica fuerza frente a velocidad queda recogida en la Figura 3.16.




Figura 3.16: Resultados de la relación fuerza-velocidad para distintos valores de la fuerza externa aplicada.

Como se puede observar en la Figura 3.16, a medida que se aumenta la fuerza aplicada, la velocidad de acortamiento disminuye. Cabe destacar que dicha velocidad por convenio es negativa, pero tal como hemos definido el desplazamiento y por ende la velocidad, ha dado lugar a un valor positivo.

3.2.2. Modelo de geometría fusiforme

En este caso, el modelo consiste en un octavo de músculo de geometría fusiforme cuyas dimensiones son $a = 5$ mm de radio de la base inferior, $b = 1$ mm de radio de la base superior y $L = 25$ mm de altura. El modelo se representa en las Figuras 3.17 y 3.18.




Figura 3.17: Geometría del modelo fusiforme.




Figura 3.18: Geometría del modelo fusiforme.

Para estudiar los fenómenos que se producen durante la contracción del músculo y poder definir adecuadamente el modelo, se han empleado los siguientes módulos del programa:

- “Mecánica de sólidos” que permite introducir el modelo de comportamiento del tejido.
- “Coordenadas curvilíneas”, que hace posible la definición de la anisotropía del tejido estableciendo la dirección de las fibras musculares en la geometría. Se ha supuesto que la dirección de la contracción coincide con la dirección de comportamiento pasivo con lo que $\mathbf{n}_0 = \mathbf{m}_0$ (Eqs. (3.4) y (3.6))
- “Ecuación en derivadas parciales en forma general”, que permite resolver la evolución de $\dot{\bar{\lambda}}_a = \frac{d\bar{\lambda}_a}{dt}$ descrita en la Eq. (3.15).

La Tabla 3.4 recoge el valor de los diferentes parámetros utilizados en el modelo tomados de trabajos previos (Calvo et al., 2010; Hernández-Gascón et al., 2013; Grasa et al., 2016).

Con este modelo se pretende analizar cómo influyen una serie de parámetros, que se recogen en la Tabla 3.5, en la contracción del músculo. Para ello, se estudiará el desplazamiento que se produce en el extremo superior del modelo durante este proceso.

Parámetro	Valor	Descripción
ρ	1000 kg/m ³	Densidad del tejido muscular
β_A	0 rad	Ángulo de \mathbf{n}_0 respecto al eje Z
c_1	8,837 kPa	Parámetro del comportamiento pasivo
c_3	9,877 kPa	Parámetro del comportamiento pasivo
c_4	2,238	Parámetro del comportamiento pasivo
\bar{I}_{4_0}	1,25	Parámetro del comportamiento pasivo
κ	$1 \cdot 10^9$ Pa	Bulk modulus
t_i	0	Tiempo inicial de contracción
t_s	0.9	Duración de la contracción
s_1	10	Pendiente inicial de la función de activación
s_2	10	Pendiente final de la función de activación
λ_{opt}	1	Alargamiento óptimo
ξ	0,16384	Controla la relación fuerza-alargamiento

Tabla 3.4: Parámetros utilizados en el modelo fusiforme.

Parámetro	Valor mínimo	Valor máximo	Descripción
P_0	1 kPa	100 kPa	Tensión isométrica máxima
v_0	1	10	Parámetro constitutivo
a	4 mm	9 mm	Radio base inferior
b	1 mm	3 mm	Radio base superior
ν	0,2	0,59	Parámetro de fricción
F_{ext}	0,005 N	0,1 N	Carga externa

Tabla 3.5: Rangos de variación de los parámetros del modelo fusiforme utilizados en el estudio.

Para este modelo se aplica también simetría en X e Y en las caras laterales y simetría en Z en la base inferior del mismo. En consecuencia, el desplazamiento en dichos contornos es nulo en la dirección de la normal a la superficie. La Figura 3.19 muestra los planos donde se han aplicado dichas condiciones.

Además, cabe destacar la orientación de las fibras musculares, que para este modelo las fibras siguen la forma del músculo, tal como se observa en la Figura 3.20.




Figura 3.19: Condiciones de simetría del modelo fusiforme.




Figura 3.20: Orientación de las fibras musculares del modelo fusiforme.

Finalmente, en cuanto al mallado del modelo, se lleva a cabo un análisis de la sensibilidad del tamaño de la malla para poder elegir aquella que muestre resultados con un cierto grado de precisión y unos costes computacionales adecuados. El número de nudos y elementos de las diferentes mallas se muestra en la Tabla 3.6. La Figura 3.21 muestras las diferentes mallas analizadas.

Descripción de la malla	Nº de nodos	Elementos
Malla extremadamente fina	5005	4320
Malla extra fina	1376	1085
Malla fina	160	90
Malla normal	140	78
Malla gruesa	100	54
Malla extremadamente gruesa	25	8

Tabla 3.6: Tamaños de malla analizados para el modelo fusiforme.




Figura 3.21: Mallas analizadas para el modelo fusiforme.

Como se observa en la Figura 3.22, la solución es prácticamente insensible al tamaño de la malla, excepto al final del tramo donde se pueden observar pequeñas distorsiones. Por ello se utiliza una malla extra fina con bastantes elementos, para obtener resultados con mayor precisión aunque esto suponga un coste computacional más elevado. Esta malla se utilizará en todos los casos de estudio de este modelo.

Una vez descrito el modelo empleado, se procede a estudiar cómo afecta la variación de cada variable, descritas en la Tabla 3.5, en la contracción del músculo. Dichos parámetros, oscilarán entre un valor mínimo y un valor máximo.




Figura 3.22: Resultados del desplazamiento en la dirección Z del extremo del modelo fusiforme para los distintos tamaños de malla.

3.2.2.1. Tensión isométrica máxima, P_0

En primer lugar, se analiza como afecta el cambio de la tensión isométrica máxima en la contracción del músculo. Al igual que para el modelo idealizado, se utiliza el programa COMSOL para obtener el desplazamiento en los distintos instantes de tiempo y se grafica la solución con el software MATLAB.

Para eso, se simulará la contracción del musculo variando este parámetro entre 1 [kPa] y 100 [kPa], tal como figura en la Tabla 3.5, y dejando fijos el resto de parámetros. La solución obtenida en un punto situado en el extremo superior del modelo con respecto al tiempo es la Figura 3.23.

Como se puede observar en la Figura 3.23, a medida que aumenta la tensión isométrica se consigue un mayor desplazamiento, lo que se traduce en una mayor contracción del músculo.

En el anexo B se muestra con detalle el mapa de color del desplazamiento en la dirección Z para la contracción del músculo en los distintos instantes de tiempo para un valor de 90 [kPa] de tensión isométrica.




Figura 3.23: Resultados del desplazamiento en la dirección Z del extremo del octavo de músculo para distintos valores de P_0 .

3.2.2.2. Parámetro constitutivo, v_0

Para estudiar cómo influye el parámetro v_0 en la contracción muscular, se procede de la misma manera que el caso anterior. Se simula el modelo variando el parámetro v_0 entre el rango establecido en la Tabla 3.2 y el resto de parámetros permanecen fijos.

Como se aprecia en la figura 3.24 y al igual que para el modelo idealizado, el parámetro v_0 influye en el tiempo de contracción del músculo. Por tanto, conforme menor es este parámetro, más tarda el músculo en contraerse.

3.2.2.3. Dimensiones características

En este caso, se analiza como se comporta el tejido cuando se modifica parte de su geometría. Para ello, se varían los parámetros a , correspondiente al radio de la base superior, entre 4 [mm] y 9 [mm] y b , correspondiente al radio de la base inferior, entre 1 [mm] y 3 [mm]. Para este estudio, se tuvo en cuenta sólo la contracción del músculo para la simulación y se prescindió de la relajación en la misma para aligerar los cálculos.

Por tanto, la gráfica del desplazamiento en el extremo del modelo frente al tiempo queda recogida en la Figura 3.25.

La Figura 3.25, muestra el desplazamiento que se produce a lo largo del tiempo al variar los parámetros del radio de la base inferior y el radio de la base superior




Figura 3.24: Resultados del desplazamiento del extremo del octavo de músculo considerando cinco valores del parámetro v_0 .




Figura 3.25: Resultados del desplazamiento del extremo del octavo de músculo en la dirección Z considerando cinco combinaciones de los parámetros a y b .

del modelo. Análogo al modelo idealizado, se puede observar en la Figura 3.25 prácticamente una única línea cuando debería haber 5, ya que hay 5 parejas de valores distintos. Por lo que se llega a la conclusión que la variación de dichos parámetros no influye de manera muy significativa en la contracción del músculo.

3.2.2.4. Parámetro de fricción, ν

Otra variable que se analiza es el parámetro ν , cuyo valor oscilara entre 0,2 y 0,59, tal como queda reflejado en la Tabla 3.5. La figura 3.26 muestra la influencia de este parámetro sobre la evolución del desplazamiento a lo largo del tiempo.




Figura 3.26: Resultados del desplazamiento en la dirección Z del octavo de músculo para distintos valores de ν .

Como se puede observar en la Figura 3.26, el parámetro ν influye en la capacidad de contracción del músculo. Es decir, si aumentamos dicho parámetro se consigue un mayor desplazamiento del extremo del músculo.

3.2.2.5. Tensión isométrica máxima, P_0 y parámetro constitutivo, v_0

Similar al modelo idealizado, después de analizar cada variable individualmente, se estudia cómo afecta la combinación de algunas variables en la contracción del músculo.

En primer lugar, se examina la pareja de variables P_0 y v_0 . Para ello, se simulará la contracción del músculo variando el parámetro de tensión isométrica entre 1 [kPa] y 100 [kPa] y el parámetro constitutivo entre 1 y 10, tal como figura en la Tabla 3.5, y dejando fijos el resto de parámetros. La solución obtenida en un punto situado en el extremo superior del modelo con respecto al tiempo es la Figura 3.27.




Figura 3.27: Resultados del desplazamiento en la dirección Z del extremo del octavo de músculo considerando cinco combinaciones de los parámetros P_0 y v_0 para el modelo idealizado.

La Figura 3.27 muestra el desplazamiento que se produce para distintos valores de P_0 y v_0 . En ella se observa que cuanto mayor es la tensión isométrica aplicada, mayor desplazamiento se consigue. Mientras que el parámetro constitutivo, v_0 , influye en el tiempo de contracción del músculo. Conforme mayor es este parámetro, antes se contrae el músculo.

3.2.2.6. Parámetro constitutivo, v_0 y parámetro de fricción, ν

Otra pareja de parámetros a analizar son la formada por el parámetro de fricción, ν , y el parámetro constitutivo, v_0 . Se procede de la misma manera que en los casos anteriores. Esta vez se varía el parámetro ν entre 0,2 y 0,59 y el parámetro v_0 entre 1 y 0. Su curva de desplazamiento frente a tiempo es la mostrada en la Figura 3.28.

En la Figura 3.28 se observa que cuanto más pequeño es el parámetro v_0 , más le cuesta al músculo contraerse. Mientras que si aumentamos el parámetro de fricción, ν , se consigue un desplazamiento mayor, es decir se contrae más el músculo.




Figura 3.28: Resultados del desplazamiento en la dirección Z del extremo del octavo de músculo considerando cinco combinaciones de los parámetros v_0 y ν para el modelo idealizado.

3.2.2.7. Contracción concéntrica

Una vez analizada la influencia de los parámetros de la Tabla 3.5, se estudia la velocidad a la que se contrae el músculo al aplicarle una carga en el extremo. Para ello se realizan ciertas modificaciones en el modelo.

En cuanto a la geometría, se coloca en el extremo superior del músculo un cubo de 3 [mm] de lado, que actuará como soporte fijo. La nueva configuración del modelo se muestra en las Figuras 3.29 y 3.30.




Figura 3.29: Geometría del modelo fusiforme para el cálculo de la contracción concéntrica




Figura 3.30: Geometría del modelo fusiforme para el cálculo de la contracción concéntrica

Con respecto a las físicas que intervienen, se mantienen los mismos módulos físicos empleados. En esa configuración y bajo el efecto de la carga exterior, se analizará la velocidad [m/s] a la que se contrae el músculo. Para ello se utiliza una sonda en uno de los extremos superiores del modelo.

En cuanto a las condiciones de contorno, se modifican y cambian algunas de las explicadas anteriormente. Por lo que estas quedan de la siguiente manera:

- Se aplica simetría en X e Y en las caras laterales del octavo de músculo y en las caras delanteras del bloque fijo. Además, se impone simetría en Z en la base inferior del octavo de músculo y en la base superior del bloque. En consecuencia, el desplazamiento en la dirección normal a esas superficies es nulo. Estas condiciones quedan representadas en la Figura 3.31.




Figura 3.31: Condiciones de simetría del modelo fusiforme para el cálculo de la contracción concéntrica.

- Se define una condición de contacto entre la cara inferior del bloque y la base superior del octavo de músculo, tal como se refleja en la Figura 3.32. Se utilizará para ello el método de penalización, para el cual se establecen un parámetro de rigidez característica y un factor de penalización de la presión de contacto.




Figura 3.32: Condición de contacto del modelo fusiforme para el cálculo de la contracción concéntrica.

- Se define una carga actuando sobre la base superior del octavo de músculo en la dirección Z que se hará variar entre 0,005 y 0,1 [N]. Dicha condición se representa en la Figura 3.33.




Figura 3.33: Carga aplicada en el modelo fusiforme para el cálculo de la contracción concéntrica.

Finalmente, en cuanto al mallado del modelo, se utiliza un tamaño de malla fina ya que se ha comprobado con los estudios anteriores realizados, que se obtienen datos precisos aunque el coste computacional sea un poco elevado.

Una vez descrito el modelo empleado, se estudia como varía la velocidad a la que se contrae el músculo al aplicarle distintos valores de carga en el extremo.

Para ello, se utiliza el programa COMSOL para obtener la velocidad de contracción en los distintos instantes de tiempo y se selecciona el valor máximo. Posteriormente, se representa la solución con el software MATLAB.

Por tanto, la gráfica fuerza frente a velocidad se muestra en la Figura 3.34. Cabe destacar que la velocidad de acortamiento por convenio es negativa. Por tanto, cuanto más negativa sea esta velocidad, el músculo se contraerá más rápido. Como se puede observar en la Figura 3.34, a medida que se disminuye la fuerza aplicada, la velocidad de acortamiento aumenta.




Figura 3.34: Resultados de la relación fuerza-velocidad para distintos valores de la fuerza externa aplicada.

3.3. Simulación de la contracción del músculo vasto intermedio humano

En este caso, se presenta el modelo de un músculo real, en concreto del músculo vasto intermedio, que es uno de los músculos que forma parte del cuádriceps. La Figura 3.35 muestra la ubicación de este músculo en el cuerpo humano.




Figura 3.35: Músculo vasto intermedio en el cuerpo humano

Este modelo únicamente se va a utilizar para el estudio mediante redes neuronales pero se refleja en este apartado la descripción del modelo. La geometría del mismo queda reflejada en las Figuras 3.36 y 3.37.




Figura 3.36: Geometría del modelo del músculo vasto intermedio.

Para estudiar los fenómenos que se producen durante la contracción del músculo y poder definir adecuadamente el modelo, se han empleado los siguientes módulos del programa:

- “Mecánica de sólidos”, que permite introducir el modelo de comportamiento del tejido.




Figura 3.37: Geometría del modelo del músculo vasto intermedio.

- “Coordenadas curvilíneas”, que hace posible la definición de la anisotropía del tejido estableciendo la dirección de las fibras musculares en la geometría. Se ha supuesto que la dirección de la contracción coincide con la dirección de comportamiento pasivo con lo que $\mathbf{n}_0 = \mathbf{m}_0$ (Eqs. (3.4) y (3.6))
- “Ecuación en derivadas parciales en forma general”, que permite resolver la evolución de $\dot{\lambda}_a = \frac{d\lambda_a}{dt}$ descrita en la Eq. (3.15).

La Tabla 3.7 recoge el valor de los diferentes parámetros utilizados en el modelo tomados de trabajos previos (Calvo et al., 2010; Hernández-Gascón et al., 2013; Grasa et al., 2016).

Con este modelo se pretende analizar como influye la tensión isométrica máxima, que se recoge en la Tabla 3.8, en la contracción del músculo. Para ello, se estudiará el desplazamiento que se produce en el extremo inferior del modelo durante este proceso.

Sobre el modelo se impone una restricción fija en la base superior, en consecuencia, el desplazamiento en dicho contorno es nulo. La Figura 3.38 muestra el plano donde se ha aplicado esta condición.

Parámetro	Valor	Descripción
ρ	1000 kg/m ³	Densidad del tejido muscular
β_A	0 rad	Ángulo de \mathbf{n}_0 respecto al eje Z
c_1	8,837 kPa	Parámetro del comportamiento pasivo
c_3	9,877 kPa	Parámetro del comportamiento pasivo
c_4	2,238	Parámetro del comportamiento pasivo
\bar{I}_{40}	1,25	Parámetro del comportamiento pasivo
κ	$1 \cdot 10^9$ Pa	Bulk modulus
t_i	0	Tiempo inicial de contracción
t_s	0.9	Duración de la contracción
s_1	10	Pendiente inicial de la función de activación
s_2	10	Pendiente final de la función de activación
λ_{opt}	1	Alargamiento óptimo
ξ	0,16384	Controla la relación fuerza-alargamiento
v_0	6	Parámetro constitutivo
ν	0,59	Parámetro de fricción

Tabla 3.7: Parámetros utilizados en el modelo del músculo vasto intermedio

Parámetro	Valor mínimo	Valor máximo	Descripción
P_0	100 kPa	1000 kPa	Tensión isométrica máxima

Tabla 3.8: Rango de variación de la tensión isométrica máxima del modelo del músculo vasto intermedio utilizado en el estudio.




Figura 3.38: Condición de restricción fija del modelo del músculo vasto intermedio.

Además, cabe destacar la orientación de las fibras musculares, que para este modelo las fibras siguen la forma del músculo, tal como se observa en la Figura 3.39.




Figura 3.39: Orientación de las fibras musculares del modelo vasto intermedio.

En cuanto al mallado del modelo, se lleva a cabo un análisis de la sensibilidad del tamaño de la malla para poder elegir aquella que muestre resultados de manera óptima con un coste computacional reducido. El número de nudos y elementos de las diferentes mallas se muestra en la Tabla 3.9. La Figura 3.40 muestra las diferentes mallas analizadas.

Descripción de la malla	Nº de nodos	Elementos
Malla extremadamente fina	8003	6396
Malla fina	196	78
Malla normal	80	59
Malla más gruesa	42	12

Tabla 3.9: Tamaños de malla analizados para el modelo del músculo vasto intermedio




Figura 3.40: Mallas analizadas para el modelo del músculo vasto intermedio

Finalmente, se elige un tamaño de malla más gruesa con pocos elementos para poder simular el modelo y que los costes computacionales no sean excesivamente elevados. El mallado del modelo queda representado en la Figura 3.41




Figura 3.41: Malla para el modelo del músculo vasto intermedio.

Una vez descrito el modelo empleado, se procede a estudiar como afecta la variación de la tensión isométrica máxima, descrita en la Tabla 3.8, en la contracción del músculo. Este parámetro servirá como variable de entrada en el entrenamiento de la red neuronal.

3.3.0.1. Tensión isométrica máxima, P_0

En primer lugar, se analiza cómo afecta el cambio de la tensión isométrica máxima en la contracción del músculo. Para ello, se utiliza el programa COMSOL para obtener el desplazamiento en los distintos instantes de tiempo y se grafica la solución con el software MATLAB.

Para eso, se simulará la contracción del musculo variando este parámetro entre 100 [kPa] y 1000 [kPa], tal como figura en la Tabla 3.8, y dejando fijos el resto de parámetros. La solución obtenida en un punto situado en el extremo inferior del modelo con respecto al tiempo se muestra en la Figura 3.42.

Como se puede observar en la Figura 3.42, si se aumenta la tensión isométrica se consigue un mayor desplazamiento, lo que se traduce en una mayor contracción del músculo.

En el Anexo C se muestra con detalle el mapa de color para la contracción del músculo en los distintos instantes de tiempo para un valor de 0,7 [MPa] de tensión isométrica.




Figura 3.42: Resultados del desplazamiento en la dirección Z del extremo del modelo vasto intermedio para distintos valores de P_0 .

Capítulo 4

Predicción de la contracción del tejido utilizando redes neuronales

Una vez descritos los modelos de elementos finitos empleados y analizado cómo evoluciona la contracción del músculo ante distintos estímulos, en este capítulo se va a explicar el proceso de generación de muestras y entrenamiento de las redes neuronales para cada modelo. Además, se comparará la predicción obtenida mediante redes con la solución obtenida con el programa COMSOL para comprobar su validez.

4.1. Generación de muestras

La generación de muestras para el entrenamiento de redes neuronales requiere un gran coste computacional, por ello se conecta el software MATLAB con el servidor de COMSOL para lanzar las simulaciones. De esta manera, se consiguen optimizar los tiempos de trabajo y obtener datos de manera automatizada.

Análogo al estudio de sensibilidad mostrado anteriormente, se simula la contracción del músculo variando distintos parámetros para generar un gran número de resultados que constituirá la población de modelos. Esta población variará en número para detectar cuál es la cantidad óptima con la que obtener predicciones adecuadas.

De las variables descritas en las Tablas 3.2 y 3.5 se escogen aquellas a las que el modelo resulta más sensible y de interés para el entrenamiento de las redes neuronales. Estos parámetros estarán acotados, es decir, oscilarán entre un valor máximo y un valor mínimo. Además, la generación de muestras será uniforme para que todos los valores tengan la misma probabilidad de aparición.

4.2. Entrenamiento de las redes

El entrenamiento de las redes neuronales se ha llevado a cabo en el entorno Google Colaboratory, que nos permite ejecutar y programar en Python así como utilizar distintas librerías ya disponibles.

Para ello, se necesitan unas variables de entrada a la red. Dichas entradas, son las variables descritas anteriormente en las Tablas 3.2 y 3.5. Mientras que los datos de salida (predicciones de la red) corresponden al desplazamiento que se produce en uno de los extremos superiores del modelo.

Un aspecto fundamental en el entrenamiento de las redes neuronales es la elección del número de capas ocultas de cada red. Las redes funcionan a través de capas de neuronas y, cuantas más capas existan, más profunda es la red y más capacidad de aprendizaje tiene. Aunque a medida que se aumenta el número de capas, el coste computacional para su entrenamiento aumenta. Por ello, se busca establecer un equilibrio entre la elección de capas y los tiempos de simulación. En este caso, se ha trabajado con 3, 7 y 9 capas intermedias. Cada capa intermedia estará formada por 25 neuronas o múltiplos de 25 siendo la capa más profunda, empleada en uno de los modelos, de 300 neuronas.

Otro aspecto a considerar en el entrenamiento de las redes neuronales es conocer la configuración de los datos de las muestras. Es decir, saber cuántas muestras se reserva el código para el entrenamiento de la red y cuantas para la validación de la predicción de la red neuronal. Para este estudio, se ha establecido un tamaño de validación del 20 % de las muestras. Por tanto, para el caso de estudio de 100 muestras se reservarán 20 para la validación y en el caso de 1000 muestras, se reservan 200.

Por último, se evalúa la capacidad de predicción de la red. Para ello se analiza la función de perdidas o error cuadrático medio (MSE), el cual indica el ajuste entre los datos estimados por la red de los datos reales, es decir, mide que tan lejos esta la estimación del valor real. La expresión para calcular el MSE es la ecuación (4.1)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_1 - y_2)^2 \quad (4.1)$$

donde n es el número total de muestras, y_1 es el valor real e y_2 es el valor estimado.

Si los valores de los resultados de la función de perdidas son altos significa que la red neuronal no predice adecuadamente, mientras que si se tienen valores pequeños, el funcionamiento de la red neuronal es correcto.

Otra función a tener en cuenta es la función de coste la cual trata de determinar el error entre el valor estimado y el valor real, con el fin de optimizar los parámetros de la red neuronal. Para caracterizar esta función de costes se utiliza el error absoluto medio o MAE, el cual no es más que una medida de precisión y se calcula como la suma media de los valores absolutos de los errores. Esta expresión es la ecuación (4.2).

$$MAE = \sum_{i=1}^n \frac{|y_1 - y_2|}{n} \quad (4.2)$$

donde y_1 es el valor real, y_2 es el valor estimado y n es el número total de muestras.

En el Anexo D se muestra con detalle el código de programación de la red neuronal para uno de los modelos. Por otro lado, la Figura 4.1 muestra la estructura de una de las redes neuronales con las que se ha trabajado. En esta red se utiliza un parámetro de entrada y 3 capas intermedias para predecir el desplazamiento en la dirección Z del extremo de una de las geometrías en 25 instantes de tiempo en una contracción de 1 s.




Figura 4.1: Estructura de una de las redes neuronales utilizada con 3 capas intermedias y con 25 neuronas cada una.

4.3. Predicción en geometrías idealizadas

4.3.1. Resultados para el modelo idealizado

Una vez explicados los procesos de obtención de muestras y entrenamiento de redes neuronales, se procede a estudiar la predicción de las redes neuronales ante los distintos parámetros de entrada.

Una vez conseguida una función de pérdidas pequeña y por tanto un buen entrenamiento de la red, se grafica la predicción de la red junto con la solución obtenida mediante el programa COMSOL y se comparan ambos resultados.

En la Figura 4.2 se adjuntan las 100 muestras empleadas en el entrenamiento de la red, utilizando como variable de entrada la tensión isométrica máxima y en la que se obtiene como resultado el desplazamiento del extremo de la geometría en la dirección Z.




Figura 4.2: Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 .

En el Anexo E se muestra con detalle el resto de muestras generadas para las diferentes variables de entrada, así como las muestras para los distintos modelos estudiados.

En primer lugar, se realizan los entrenamientos para 100 muestras del modelo idealizado. El resultado del desplazamiento que se obtiene con una de las muestras reservada para la validación mediante redes neuronales y ese mismo caso obtenido por

COMSOL queda reflejado en la Figura 4.3.




Figura 4.3: Desplazamiento del extremo de la geometría en la dirección Z obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo idealizado, utilizando como entrada la tensión isométrica máxima, P_0 .

La Figura 4.3 muestra la predicción de la red y el resultado obtenido con COMSOL para el desplazamiento que se produce en el extremo superior del modelo durante la contracción muscular. En este caso, la variable de entrada a la red es la tensión isométrica máxima, P_0 .

La Figura 4.4 muestra la predicción de la red y el resultado obtenido con COMSOL para el desplazamiento que se produce en el extremo superior del modelo durante la contracción muscular. En este caso, las variables de entrada a la red son dos, el parámetro a y el parámetro b , correspondientes a la dimensión transversal del modelo idealizado.

La Figura 4.5 muestra la predicción de la red y el resultado obtenido con COMSOL para el desplazamiento que se produce en el extremo superior del modelo durante la contracción muscular. Para este estudio, las variables de entrada a la red son la tensión isométrica máxima, P_0 , la variable a y la variable b .

La Figura 4.6 muestra la predicción de la red y el resultado obtenido con COMSOL para el desplazamiento que se produce en el extremo superior del modelo durante la contracción muscular. En este caso, las variables de entrada a la red son la carga externa aplicada, el parámetro a y el parámetro b .




Figura 4.4: Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo idealizado, utilizando como entradas las variables a y b .




Figura 4.5: Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo idealizado, utilizando como entradas la tensión isométrica máxima, P_0 y las variables a y b .




Figura 4.6: Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo idealizado, utilizando como entradas la carga externa aplicada y las variables a y b .

Cabe destacar que para una o dos variables de entrada se logra el buen entrenamiento de la red con 7 capas intermedias. A medida que se aumentan las variables de entrada o aumenta la complejidad del modelo, resulta más complicado conseguir que la red trabaje de la manera esperada. Por tanto, se procedió a aumentar el número de capas intermedias para ver si se podía disminuir la función de pérdidas. Al comprobar que no se lograba disminuir esta función aumentando las capas, se realizó un pequeño cambio en la programación de la red. Dicho cambio, consistió en disminuir el parámetro *batch-size*, que es el número de muestras que el algoritmo de entrenamiento hace circular por la red simultáneamente antes de actualizar los pesos, en el bloque de entrenamiento de la red. De esta manera, la red se entrena más rápido y se logra un buen funcionamiento de la red con 3 capas intermedias.

Como se puede observar en las Figuras 4.3, 4.4, 4.5 y 4.6, los valores de las predicciones siguen la tendencia de las curvas obtenidas mediante COMSOL. Para verificarlo en la Tabla 4.1 se muestran los distintos valores de MAE obtenidos para cada caso de estudio.

Analizando los datos obtenidos en la Tabla 4.1, se comprueba que los datos de MAE para 100 muestras son valores pequeños. Esto se traduce en que las predicciones de las redes son muy uniformes y que poseen una elevada precisión y que, por tanto, se puede

Red neuronal 100 muestras	MAE (mm)
Tensión isométrica máxima, P_0	0,2390
Dimensiones características	0,0489
Tensión isométrica máxima y dimensiones características	0,3329
Carga externa aplicada y dimensiones características	0,1190

Tabla 4.1: Valores de la función MAE para cada red de 100 muestras del modelo idealizado.

afirmar su validez.

Una característica de las redes es que a medida que se aumenta el número de muestras, se consigue reducir el porcentaje de error. Es decir, se consigue reducir la función de pérdidas o MSE ya que se consigue un mejor ajuste de la red neuronal, lo que se traduce en una red más eficiente. Para verificar dicho aspecto, se generan 1000 muestras y se procede a entrenar las distintas redes de forma similar a los casos anteriores.

En la Figura 4.7 se observan los resultados obtenidos para el desplazamiento que se produce en el extremo del modelo con el software COMSOL y la predicción de la red neuronal. La variable de entrada a la red es la tensión isométrica máxima, P_0




Figura 4.7: Desplazamiento del extremo de la geometría en la dirección Z obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 1000 muestras de entrenamiento del modelo idealizado, utilizando como entrada la tensión isométrica máxima, P_0 .

En este caso, la Figura 4.8 tiene como valores de entrada a la red los parámetros a y b , que corresponden con la geometría de la sección transversal del modelo. La Figura 4.8 representa el desplazamiento que se produce en el extremo superior del modelo tanto obtenido con COMSOL como por las redes neuronales.




Figura 4.8: Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 1000 muestras de entrenamiento del modelo idealizado, utilizando como entradas las variables a y b .

La Figura 4.9 muestra el resultado del desplazamiento que se produce en el extremo del modelo durante la contracción muscular tanto el obtenido con COMSOL como la predicción de la red neuronal. En este caso, las variables de entrada a la red neuronal son la tensión isométrica máxima y las dimensiones características, a y b .




Figura 4.9: Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 1000 muestras de entrenamiento del modelo idealizado, utilizando como entradas la tensión isométrica máxima, P_0 y las variables a y b .

Para cuantificar la exactitud de las redes neuronales estudiadas se analizan los valores de MAE obtenidos con cada red. La Tabla 4.2 muestra estos valores para cada red neuronal de 1000 muestras. En ella se puede comprobar que el error que comete cada red neuronal es bastante pequeño. Por lo que la predicción de las distintas redes neuronales son muy exactas y prácticamente coinciden con los valores obtenidos por COMSOL.

Red neuronal 1000 muestras	MAE (mm)
Tensión isométrica máxima, P_0	0,1076
Dimensiones características	0,0479
Tensión isométrica máxima y dimensiones características	0,1242

Tabla 4.2: Valores de la función MAE para cada red de 1000 muestras del modelo idealizado.

Para comprobar que la red aprende de manera más eficiente, aumentando el número de muestras y empleando la misma arquitectura de red para la misma variable, se comparan los distintos valores de pérdidas obtenidos:

Analizando los datos obtenidos en la Tabla 4.3, se comprueba que los datos de pérdidas para 100 muestras son valores pequeños y que si se aumenta el número de

Función de pérdidas (mm ²)		
Variables	100 muestras	1000 muestras
P_0	0.1353	0.0525
Dimensiones características	0.0070	0.0065
P_0 y dimensiones características	0.2350	0.0372

Tabla 4.3: Valores de la función de pérdidas para 100 y 1000 muestras.

muestras, estos valores aún se consiguen reducir más. Por tanto, se corrobora que al aumentar el tamaño de muestras para el entrenamiento, se reducen las pérdidas de la red neuronal y se logra una red más eficiente.

4.3.2. Resultados para el modelo de geometría fusiforme

Una vez estudiadas las redes para el modelo idealizado, se analizó como funcionarían las redes para el modelo de geometría fusiforme. En este caso, se generaron las muestras y el entrenamiento de la red de la misma manera que para el modelo anterior. Pero al ser un modelo mucho más complejo que el fascículo muscular, se tuvieron en cuenta un par de aspectos. En primer lugar, para el estudio, se va a tener en cuenta únicamente la contracción del músculo prescindiendo de la relajación del mismo para poder aligerar los cálculos. Además, únicamente se van a generar 100 muestras para el entrenamiento de la red ya que el coste computacional de simulación es muy alto.

La Figura 4.10 muestra los resultados obtenidos para el desplazamiento que se produce en el extremo del modelo con el software COMSOL y la predicción de la red neuronal. La variable de entrada a la red es la tensión isométrica máxima, P_0

En este caso, la Figura 4.11 tiene como valores de entrada a la red los parámetros a y b , que corresponden con los parámetros de geometría del modelo. La Figura 4.11 representa el desplazamiento que se produce en el extremo superior del modelo tanto obtenido con COMSOL como por las redes neuronales.

La Figura 4.12 muestra el resultado del desplazamiento que se produce en el extremo del modelo durante la contracción muscular tanto el obtenido con COMSOL como la predicción de la red neuronal. En este caso, las variables de entrada a la red neuronal son la tensión isométrica máxima y las dimensiones características, a y b .

Por último, la Figura 4.13 muestra la predicción de la red y el resultado obtenido con COMSOL para el desplazamiento que se produce en el extremo superior del modelo durante la contracción muscular. En este caso, las variables de entrada a la red son la carga externa aplicada, el parámetro a y el parámetro b .




Figura 4.10: Desplazamiento del extremo de la geometría en la dirección Z obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo fusiforme, utilizando como entrada la tensión isométrica máxima, P_0 .




Figura 4.11: Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo fusiforme, utilizando como entradas las variables a y b .




Figura 4.12: Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo fusiforme, utilizando como entradas la tensión isométrica máxima, P_0 y las variables a y b .




Figura 4.13: Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo fusiforme, utilizando como entradas la carga externa aplicada y las variables a y b .

En este caso, para una o dos variables de entrada se logra el buen entrenamiento de la red con 9 capas intermedias. A medida que se aumentan las variables de entrada o aumenta la complejidad del modelo, resulta más complicado conseguir que la red trabaje de la manera esperada. Análogo al modelo del fascículo muscular, se aumento el número de capas intermedias para ver si se podía disminuir la función de pérdidas. Al comprobar que no se lograba disminuir esta función aumentando las capas, se disminuyó el parámetro *batch – size* en el bloque de entrenamiento de la red. De esta manera, se consigue que la red se entrene más rápido y se logra un buen funcionamiento de la red con 3 capas intermedias.

Analizando las Figuras 4.10, 4.11, 4.12 y 4.13, los valores de las predicciones siguen la tendencia de las curvas obtenidas mediante COMSOL. Para cuantificar la exactitud de las redes neuronales se estudia el error absoluto medio (MAE) cometido por cada red. Dichos valores se recogen en la Tabla 4.4.

Red neuronal 100 muestras	MAE (mm)
Tensión isométrica máxima, P_0	0,0063
Dimensiones características	0,0026
Tensión isométrica máxima y dimensiones características	0,0134
Carga externa aplicada y dimensiones características	0,0276

Tabla 4.4: Valores de la función MAE para cada red de 100 muestras del modelo de geometría fusiforme.

Como se puede observar en la Tabla 4.4, cada red neuronal presenta unos valores de MAE muy pequeños. Esto significa que las predicciones de las redes son muy uniformes y que poseen una elevada precisión y que, por tanto, también se puede afirmar su validez para este modelo.

4.4. Predicción en geometrías reales

4.4.1. Resultados para el modelo del músculo vasto intermedio humano

En este último caso, se analiza cómo funcionaría la predicción de las redes neuronales para un modelo real y complejo, como es el caso del músculo vasto intermedio.

Se generaron las muestras y el entrenamiento de la red de la misma manera que para los modelos anteriormente descritos. Al ser un modelo complejo, se tuvieron en cuenta un par de aspectos.

En primer lugar, para el estudio, se va a tener en cuenta únicamente la contracción del músculo prescindiendo de la relajación del mismo para poder aligerar los cálculos. Además, únicamente se van a generar 100 muestras para el entrenamiento de la red ya que el coste computacional de simulación es muy alto.

Una vez comentados dichos aspectos, la Figura 4.14 muestra la gráfica obtenida para el modelo vasto intermedio, siendo la variable de entrada el parámetro de tensión isométrica máxima, P_0 .




Figura 4.14: Desplazamiento del extremo de la geometría en la dirección Z obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo vasto intermedio, utilizando como entrada la tensión isométrica máxima, P_0 .

En este caso, al ser una única variable, se logra un buen entrenamiento de la red aumentando el número de capas intermedias. Por lo tanto se consigue un buen funcionamiento de la misma con 11 capas intermedias.

Como se puede observar en la gráfica de la Figura 4.14, los valores de las predicciones siguen la tendencia de las curvas obtenidas mediante COMSOL. Para poder cuantificar su exactitud se analiza el error absoluto medio cometido. Dicho valor queda reflejado en la Tabla 4.5.

Red neuronal 100 muestras	MAE (mm)
Tensión isométrica máxima, P_0	0,2742

Tabla 4.5: Valores de la función MAE para cada red de 100 muestras del modelo del músculo vasto intermedio humano.

Analizando el valor obtenido del MAE en la Tabla 4.5, se comprueba que este es pequeño y que por tanto, la predicción de la red tiene una elevada precisión y que coincide prácticamente con el resultado obtenido con COMSOL.

Por ello, también se puede afirmar la validez de las redes neuronales para modelos más complejos y reales como es este caso.

Capítulo 5

Conclusiones y líneas futuras

En este capítulo, se recogen las conclusiones a las que se ha llegado con este estudio y se comentan una serie de posibles líneas futuras a desarrollar a partir del mismo.

5.1. Conclusiones

Tal y como se ha comentado en el apartado 1.3 de esta memoria, el objetivo global de este proyecto consiste en desarrollar una metodología computacional con la capacidad de poder predecir el comportamiento del tejido muscular esquelético en tiempo real.

Este capítulo servirá para discernir si el uso del aprendizaje profundo y en concreto, las redes neuronales, son eficaces para lograr dicho objetivo. Para ello se han desarrollado varios estudios con diferentes tipologías.

En primer lugar, se ha diseñado un modelo simple de elementos finitos en 3D. Aunque este modelo no sea el que mejor represente la forma de un músculo real por su sencilla geometría, consistía en una buena toma de contacto para aprender cómo era la respuesta del tejido durante la contracción muscular. Además dicho modelo ha servido para aprender a trabajar con los distintos programas y conocer el funcionamiento y el comportamiento de las redes neuronales. A pesar de ser un modelo simple, cabe destacar la elevada exactitud obtenida en las predicciones de las redes neuronales. Por lo que, se podía intuir el gran abanico de posibilidades que ofrecen dichas redes.

Posteriormente, se analizó un modelo de elementos finitos más complejo que el anterior, en concreto un octavo de una geometría de músculo fusiforme, para estudiar el comportamiento de un músculo que, si bien continúa siendo una idealización permite incorporar direcciones de fibras musculares no paralelas. Dichos músculos se caracterizan por su forma de huso, alargada y más estrecha en los extremos que en la parte central. Al ser un modelo más complejo, cabía la posibilidad de

que las predicciones realizadas por las redes neuronales no fuesen lo suficientemente precisas. No obstante, se ha podido comprobar que utilizando arquitecturas adecuadas y adaptando el método de entrenamiento, las predicciones obtenidas logran unos resultados muy exactos con respecto al modelo simulado en el software COMSOL Multiphysics.

Por último, se estudió un modelo de elementos finitos real, en concreto un modelo del músculo vasto intermedio humano. Dicho modelo se utilizó para comprobar si las redes neuronales podrían trabajar de manera eficiente ante geometrías reales y complejas. Análogo al caso anterior, cabía la posibilidad de que no se lograra un entrenamiento eficiente de la red debido a la complejidad que presenta dicho modelo. Sin embargo, al comparar las predicciones obtenidas de la red con los resultados obtenidos mediante simulación, se llegó a la conclusión de que las predicciones de las redes son muy uniformes y que poseen una elevada precisión. Por ello, también se puede afirmar la validez de las redes neuronales para modelos más complejos y reales como es este caso.

Finalmente, cabe destacar un aspecto clave de las redes neuronales es el tamaño de la generación de las muestras para su posterior uso en el entrenamiento de las redes neuronales. Cuanto mayor es el número de muestras generadas, más precisión poseen las redes. Dicho aspecto, se ha podido comprobar comparando la función de pérdidas para 100 y 1000 muestras del modelo idealizado, en concreto del fascículo muscular. Tal como figura en la Tabla 4.3, a medida que se aumenta el número de muestras, se consigue reducir el porcentaje de error de la red neuronal, lo que se traduce en una red más eficiente. Además, cabe señalar que cuanto mayor es el número de muestras, más tiempo cuesta la simulación de las mismas y el entrenamiento de la red.

Para concluir, otra característica fundamental de las redes neuronales que hay que tener en cuenta es el número de capas ocultas de la red. A mayor número de capas, más compleja es la red y más capacidad de aprendizaje tiene aunque su entrenamiento también es más costoso. Dicho aspecto, se ha podido comprobar en los modelos más complejos en los que se ha utilizado mayor número de capas para obtener una red más precisa. Cabe destacar que si se utilizan varias variables de entrada en la red de manera simultánea o el modelo es de especial complejidad, a pesar de aumentar el número de capas no se consigue un buen entrenamiento de la red. Por lo que hay que modificar algún parámetro de la programación de la red, como por ejemplo el parámetro *batch-size*, para conseguir los resultados deseados.

5.2. Líneas futuras

Este trabajo sirve como punto de partida para entrenar redes neuronales más complejas que permitan predecir el comportamiento del tejido muscular esquelético. Las posibles ampliaciones que podría tener este proyecto son las siguientes:

- Aplicar una carga en el extremo al modelo del músculo vasto intermedio para calcular y analizar cuál es la respuesta para de esta forma evaluar la capacidad de aprendizaje de la red.
- Incluir en el estudio más variables de entrada con las que llevar a cabo el entrenamiento de redes neuronales. Estas variables de entrada podrían comprender las coordenadas iniciales de los nudos de la malla y de esta manera tratar de predecir su configuración deformada.
- Analizar el comportamiento de otros modelos de músculos del cuerpo humano con diferentes arquitecturas (músculos planos, penados, bipenados, etc.) y evaluar la capacidad de aprendizaje de la red.
- Estudiar el comportamiento de manera simultánea de parejas de músculos antagonistas ante una misma carga, como podrían ser el biceps y el triceps.
- Intentar crear un modelo formado por varios músculos para comprender el comportamiento del conjunto. Un ejemplo de este modelo podría ser, el músculo cuádriceps el cual esta formado por cuatro músculos y combinar la respuesta de varias redes.

Capítulo 6

Bibliografía

Begoña Calvo, Angélica Ramírez, Ana Alonso, Jorge Grasa, Fernando Soteras, Rosario Osta, and María Jesús Muñoz. Passive nonlinear elastic behaviour of skeletal muscle: Experimental results and model formulation. *Journal of Biomechanics*, 43(2):318–325, 2010. ISSN 0021-9290. doi: <https://doi.org/10.1016/j.jbiomech.2009.08.032>.

Yulia Gavrilova. A guide to deep learning and neural networks (accessed june 17, 2021), 2020. URL <https://serokell.io/blog/deep-learning-and-neural-network-guide>.

Jorge Grasa, Angélica Ramírez, Rosario Osta, María Jesús Muñoz, Fernando Soteras, and Begoña Calvo. A 3D active-passive numerical skeletal muscle model incorporating initial tissue strains. validation with experimental results on rat tibialis anterior muscle. *Biomech Model Mechanobiol*, 10(5):779–87, Oct 2011. doi: [10.1007/s10237-010-0273-z](https://doi.org/10.1007/s10237-010-0273-z).

Jorge Grasa, Marta Sierra, Nathan Lauzeral, María J. Muñoz, Francisco J. Miana-Mena, and Begoña Calvo. Active behavior of abdominal wall muscles: Experimental results and numerical model formulation. *Journal of the Mechanical Behavior of Biomedical Materials*, 61:444–454, 2016. ISSN 1751-6161. doi: <https://doi.org/10.1016/j.jmbbm.2016.04.013>.

Arthur C. Guyton and John E. Hall. *Tratado de fisiología médica*. 11 edition, 2011.

Belén Hernández-Gascón, Jorge Grasa, Begoña Calvo, and José Félix Rodríguez. A 3D electro-mechanical continuum model for simulating skeletal muscle contraction. *J Theor Biol*, 335:108–18, Oct 2013. doi: [10.1016/j.jtbi.2013.06.029](https://doi.org/10.1016/j.jtbi.2013.06.029).

iat. Deep learning, aprendizaje profundo y redes

- neuronales (accessed june 17, 2021), 2021. URL <https://iat.es/tecnologias/inteligencia-artificial/deep-learning/>.
- IBM Cloud Education. What is artificial intelligence (AI)? (accessed june 17, 2021), 2021. URL <https://www.ibm.com/cloud/learn/what-is-artificial-intelligence>.
- Nikolaus Kriegeskorte and Tal Golan. Neural network models and deep learning. *Current Biology*, 29:R231–R236, 2019. ISSN 09609822. doi: <https://doi.org/10.1016/j.cub.2019.02.034>.
- James Moor. The dartmouth college artificial intelligence conference: The next fifty years. *AI Magazine*, 27:87–91, 01 2006.
- Manuel Megías Pacheco, Pilar Molist García, and Manuel Ángel Pombal Diego. Tejidos animales. tejido muscular. atlas de histología vegetal y animal (accessed june 17, 2021), 2019. URL https://mmegias.webs.uvigo.es/guiada_a_muscular-c.php.
- Angélica Ramírez, Jorge Grasa, Aana Alonso, Fernando Soteras, Rosario Osta, María J. Muñoz, and Begoña Calvo. Active response of skeletal muscle: In vivo experimental results and model formulation. *Journal of Theoretical Biology*, 267(4):546–553, 2010. doi: <https://doi.org/10.1016/j.jtbi.2010.09.018>.
- Michael Schünke, Erik Schulte, Udo Schumacher, Markus Voll, Karl Wesker, Ana Heimann, and Alex Merí Vived. *Prometheus: texto y atlas de anatomía*. 2nd edition, 2011.

Lista de Figuras

1.1. Diferentes tipos de músculos	2
1.2. Estructura del tejido músculo esquelético	3
1.3. Organización del músculo esquelético, desde el nivel macroscópico al nivel molecular	4
1.4. Estados relajado y contraído de un sarcómero en la contracción muscular	5
2.1. Diferencias entre Inteligencia Artificial, Aprendizaje Automático y Aprendizaje Profundo.	11
2.2. Estructura de las redes neuronales	13
2.3. Esquema de funcionamiento de una red neuronal	14
3.1. Geometría del modelo idealizado.	21
3.2. Condiciones de simetría del modelo idealizado.	23
3.3. Orientación de las fibras musculares del modelo idealizado.	24
3.4. Mallas analizadas para el modelo idealizado.	25
3.5. Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo para los distintos tamaños de malla.	26
3.6. Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo para distintos valores de P_0	27
3.7. Resultados del desplazamiento del extremo del paralelepípedo considerando cinco valores del parámetro v_0	28
3.8. Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo considerando cinco combinaciones de la sección transversal para el modelo idealizado.	29

3.9. Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo para distintos valores de ν	30
3.10. Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo considerando cinco combinaciones de los parámetros P_0 y v_0 para el modelo idealizado.	31
3.11. Resultados del desplazamiento en la dirección Z del extremo del paralelepípedo considerando cinco combinaciones de los parámetros v_0 y ν para el modelo idealizado.	32
3.12. Geometría del modelo idealizado para el cálculo de la contracción concéntrica.	33
3.13. Condiciones de simetría del modelo idealizado para el cálculo de la contracción concéntrica.	33
3.14. Condición de contacto del modelo idealizado para el cálculo de la contracción concéntrica.	34
3.15. Carga aplicada en el modelo idealizado para el cálculo de la contracción concéntrica.	34
3.16. Resultados de la relación fuerza-velocidad para distintos valores de la fuerza externa aplicada.	35
3.17. Geometría del modelo fusiforme.	36
3.18. Geometría del modelo fusiforme.	36
3.19. Condiciones de simetría del modelo fusiforme.	38
3.20. Orientación de las fibras musculares del modelo fusiforme.	38
3.21. Mallas analizadas para el modelo fusiforme.	39
3.22. Resultados del desplazamiento en la dirección Z del extremo del modelo fusiforme para los distintos tamaños de malla.	40
3.23. Resultados del desplazamiento en la dirección Z del extremo del octavo de músculo para distintos valores de P_0	41
3.24. Resultados del desplazamiento del extremo del octavo de músculo considerando cinco valores del parámetro v_0	42
3.25. Resultados del desplazamiento del extremo del octavo de músculo en la dirección Z considerando cinco combinaciones de los parámetros a y b	42

3.26. Resultados del desplazamiento en la dirección Z del octavo de músculo para distintos valores de ν	43
3.27. Resultados del desplazamiento en la dirección Z del extremo del octavo de músculo considerando cinco combinaciones de los parámetros P_0 y v_0 para el modelo idealizado.	44
3.28. Resultados del desplazamiento en la dirección Z del extremo del octavo de músculo considerando cinco combinaciones de los parámetros v_0 y ν para el modelo idealizado.	45
3.29. Geometría del modelo fusiforme para el cálculo de la contracción concéntrica	45
3.30. Geometría del modelo fusiforme para el cálculo de la contracción concéntrica	46
3.31. Condiciones de simetría del modelo fusiforme para el cálculo de la contracción concéntrica.	46
3.32. Condición de contacto del modelo fusiforme para el cálculo de la contracción concéntrica.	47
3.33. Carga aplicada en el modelo fusiforme para el cálculo de la contracción concéntrica.	47
3.34. Resultados de la relación fuerza-velocidad para distintos valores de la fuerza externa aplicada.	48
3.35. Músculo vasto intermedio en el cuerpo humano	49
3.36. Geometría del modelo del músculo vasto intermedio.	49
3.37. Geometría del modelo del músculo vasto intermedio.	50
3.38. Condición de restricción fija del modelo del músculo vasto intermedio. .	51
3.39. Orientación de las fibras musculares del modelo vasto intermedio. . . .	52
3.40. Mallas analizadas para el modelo del músculo vasto intermedio	52
3.41. Malla para el modelo del músculo vasto intermedio.	53
3.42. Resultados del desplazamiento en la dirección Z del extremo del modelo vasto intermedio para distintos valores de P_0	54
4.1. Estructura de una de las redes neuronales utilizada con 3 capas intermedias y con 25 neuronas cada una.	57

4.2. Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0	58
4.3. Desplazamiento del extremo de la geometría en la dirección Z obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo idealizado, utilizando como entrada la tensión isométrica máxima, P_0	59
4.4. Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo idealizado, utilizando como entradas las variables a y b	60
4.5. Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo idealizado, utilizando como entradas la tensión isométrica máxima, P_0 y las variables a y b	60
4.6. Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo idealizado, utilizando como entradas la carga externa aplicada y las variables a y b	61
4.7. Desplazamiento del extremo de la geometría en la dirección Z obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 1000 muestras de entrenamiento del modelo idealizado, utilizando como entrada la tensión isométrica máxima, P_0	62
4.8. Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 1000 muestras de entrenamiento del modelo idealizado, utilizando como entradas las variables a y b	63
4.9. Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 1000 muestras de entrenamiento del modelo idealizado, utilizando como entradas la tensión isométrica máxima, P_0 y las variables a y b	64
4.10. Desplazamiento del extremo de la geometría en la dirección Z obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo fusiforme, utilizando como entrada la tensión isométrica máxima, P_0	66

4.11. Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo fusiforme, utilizando como entradas las variables a y b	66
4.12. Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo fusiforme, utilizando como entradas la tensión isométrica máxima, P_0 y las variables a y b	67
4.13. Desplazamiento en la dirección Z del extremo de la geometría obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo fusiforme, utilizando como entradas la carga externa aplicada y las variables a y b	67
4.14. Desplazamiento del extremo de la geometría en la dirección Z obtenido con COMSOL (línea continua) y con la red neuronal (puntos) para 100 muestras de entrenamiento del modelo vasto intermedio, utilizando como entrada la tensión isométrica máxima, P_0	69
A.1. Evolución de la contracción del modelo idealizado para un valor de $P_0 = 90$ [kPa] desde $t = 0$ s hasta $t = 0,3$ s.	87
A.2. Evolución del desplazamiento en la dirección Z del modelo idealizado para un valor de $P_0 = 90$ [kPa] desde $t = 0,4$ s hasta $t = 0,9$ s.	88
B.1. Evolución del desplazamiento en la dirección Z del modelo fusiforme para un valor de $P_0 = 90$ [kPa] desde $t = 0$ s hasta $t = 0,3$ s.	89
B.2. Evolución del desplazamiento en la dirección Z del modelo fusiforme para un valor de $P_0 = 90$ [kPa] desde $t = 0,4$ s hasta $t = 0,7$ s.	90
B.3. Evolución del desplazamiento en la dirección Z del modelo fusiforme para un valor de $P_0 = 90$ [kPa] desde $t = 0,8$ s hasta $t = 1$ s.	90
C.1. Evolución del desplazamiento en la dirección Z del modelo vasto intermedio para un valor de $P_0 = 0,7$ [MPa] desde $t = 0$ s hasta $t = 0,06$ s.	91
C.2. Evolución del desplazamiento en la dirección Z del modelo vasto intermedio para un valor de $P_0 = 0,7$ [MPa] desde $t = 0,08$ s hasta $t = 0,14$ s.	92

C.3. Evolución del desplazamiento en la dirección Z del modelo vasto intermedio para un valor de $P_0 = 0,7$ [MPa] desde $t = 0,16$ s hasta $t = 0,2$ s.	92
E.1. Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0	98
E.2. Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada los parámetros a y b	98
E.3. Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 y los parámetros a y b	99
E.4. Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la carga externa aplicada y los parámetros a y b	99
E.5. Población de 1000 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0	100
E.6. Población de 1000 muestras utilizadas en el entrenamiento de la red, utilizando como entrada los parámetros a y b	100
E.7. Población de 1000 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 y los parámetros a y b	101
E.8. Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0	101
E.9. Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada los parámetros a y b	102
E.10. Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 y los parámetros a y b	102
E.11. Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la carga externa aplicada y los parámetros a y b	103
E.12. Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0	103

Lista de Tablas

3.1. Parámetros utilizados en el modelo idealizado.	22
3.2. Rangos de variación de los parámetros del modelo idealizado utilizados en el estudio	23
3.3. Tamaños de malla analizados para el modelo idealizado.	24
3.4. Parámetros utilizados en el modelo fusiforme.	37
3.5. Rangos de variación de los parámetros del modelo fusiforme utilizados en el estudio.	37
3.6. Tamaños de malla analizados para el modelo fusiforme.	38
3.7. Parámetros utilizados en el modelo del músculo vasto intermedio . . .	51
3.8. Rango de variación de la tensión isométrica máxima del modelo del músculo vasto intermedio utilizado en el estudio.	51
3.9. Tamaños de malla analizados para el modelo del músculo vasto intermedio	52
4.1. Valores de la función MAE para cada red de 100 muestras del modelo idealizado.	62
4.2. Valores de la función MAE para cada red de 1000 muestras del modelo idealizado.	64
4.3. Valores de la función de pérdidas para 100 y 1000 muestras.	65
4.4. Valores de la función MAE para cada red de 100 muestras del modelo de geometría fusiforme.	68
4.5. Valores de la función MAE para cada red de 100 muestras del modelo del músculo vasto intermedio humano.	70

Anexos

Anexos A

Evolución del campo de desplazamientos para el modelo idealizado

En este primer anexo, se presenta la evolución de la contracción del músculo que se produce para un valor de tensión isométrica de 90 [kPa]. Para llevarlo a cabo, se han escogido 9 instantes de tiempo, cada 0.1s, con el fin de apreciar su evolución. Estos instantes reflejan la distribución del desplazamiento en la dirección Z durante la contracción muscular y hacen referencia a las curvas de la Figura 3.6, la cual representa los resultados del desplazamiento del extremo del prisma para distintos valores de P_0 .




Figura A.1: Evolución de la contracción del modelo idealizado para un valor de $P_0 = 90$ [kPa] desde $t = 0$ s hasta $t = 0,3$ s.




Figura A.2: Evolución del desplazamiento en la dirección Z del modelo idealizado para un valor de $P_0 = 90$ [kPa] desde $t = 0,4$ s hasta $t = 0,9$ s.

Anexos B

Evolución del campo de desplazamientos para el modelo de geometría fusiforme

Al igual que para el modelo idealizado, en este anexo, se muestra la evolución de la contracción del músculo que se produce para un valor de tensión isométrica de 90 [kPa]. Para llevarlo a cabo, se han escogido 11 instantes de tiempo, cada 0.1s, con el fin de apreciar su evolución. Estos instantes reflejan la evolución del campo de desplazamientos en la dirección Z de la geometría durante la contracción muscular y hacen referencia a las curvas de la Figura 3.23, la cual representa los resultados del desplazamiento del extremo del octavo de músculo para distintos valores de P_0 .




Figura B.1: Evolución del desplazamiento en la dirección Z del modelo fusiforme para un valor de $P_0 = 90$ [kPa] desde $t = 0$ s hasta $t = 0,3$ s.




Figura B.2: Evolución del desplazamiento en la dirección Z del modelo fusiforme para un valor de $P_0 = 90$ [kPa] desde $t = 0,4$ s hasta $t = 0,7$ s.




Figura B.3: Evolución del desplazamiento en la dirección Z del modelo fusiforme para un valor de $P_0 = 90$ [kPa] desde $t = 0,8$ s hasta $t = 1$ s.

Anexos C

Evolución del campo de desplazamientos para el modelo del músculo vasto intermedio humano

Al igual que para los modelos anteriores, en este anexo, se muestra la evolución de la contracción del músculo que se produce para un valor de tensión isométrica de 0,7 [MPa]. Para llevarlo a cabo, se han escogido 11 instantes de tiempo, cada 0,02 s, con el fin de apreciar su evolución. Estos instantes reflejan la distribución del desplazamiento en la dirección Z durante la contracción muscular y hacen referencia a las curvas de la Figura 3.42, la cual representa los resultados del desplazamiento del extremo del músculo vasto intermedio para distintos valores de P_0 .




Figura C.1: Evolución del desplazamiento en la dirección Z del modelo vasto intermedio para un valor de $P_0 = 0,7$ [MPa] desde $t = 0$ s hasta $t = 0,06$ s.




Figura C.2: Evolución del desplazamiento en la dirección Z del modelo vasto intermedeio para un valor de $P_0 = 0,7$ [MPa] desde $t = 0,08$ s hasta $t = 0,14$ s.




Figura C.3: Evolución del desplazamiento en la dirección Z del modelo vasto intermedio para un valor de $P_0 = 0,7$ [MPa] desde $t = 0,16$ s hasta $t = 0,2$ s.

Anexos D

Código de programación para una red neuronal

En este anexo, se enseña el código de programación para el entrenamiento de una red neuronal para el modelo idealizado, cuyo valor de entrada es la tensión isométrica máxima, P_0 . Cabe destacar que para el entrenamiento de la red con 2 o más variables de entrada, únicamente se modifican las definiciones de entradas y salidas de la red y el número de capas. Para el resto de modelos, se procede de la misma manera y se utiliza el mismo código de programación que para el modelo idealizado.

Código para entrenar Feed Forward Neural Network TFG Eva.

TRAIN DATA: Desplazamientos en la dirección Z (mm) obtenidos para el músculo prismático 10x10x100 mm para diferentes valores de la tensión isométrica máxima P_0

PREDICTION: Valor del desplazamiento en Z (mm) en 25 instantes de tiempo a lo largo del tiempo de contracción (1 s)

Importamos diferentes librerías necesarias para ejecutar el código:

```
# TensorFlow and tf.keras
import tensorflow as tf
from tensorflow import keras
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Dropout,
Flatten, Dense

# Commonly used modules
import numpy as np
import os
import sys

# Images, plots, display, and visualization
import matplotlib.pyplot as plt
import pandas as pd
import seaborn as sns
import cv2
import IPython
from six.moves import urllib
```

Hacemos accesible nuestro directorio en google drive donde tenemos almacenados los archivos necesarios:

```
from google.colab import drive
drive.mount('/content/drive')
my_data_dir='/content/drive/Shared drives/TFG_Eva_Velamazan/'# Directorio donde se encuentra el fichero con los datos de entrenamiento
name=my_data_dir + '/training_data_muscle_prism_U_z_from_P_0.csv'
#Nombre del fichero con los datos
training_data = pd.read_csv(name, header=None, index_col=False)
training_data #Visualizo el contenido del fichero como comprobación
```

Definimos las entradas a la red para el entrenamiento:

```
Input = training_data.iloc[:,0]
Input                                     # Comentar/Descomentar para comprobar
```

Definimos las salidas para el entrenamiento:

```
Output = training_data.iloc[:,1:26]
Output                                     # Comentar/Descomentar para comprobar
```

```
X=Input.values
Y=Output.values
```

Dividimos los datos para el entrenamiento y para comprobar la red:

```
from sklearn.model_selection import train_test_split
X_train, X_test, Y_train, Y_test = train_test_split(X, Y, test_size
=0.2, random_state=42)
#X_train.shape          # Comentar/Descomentar para verificar el
tamaño de la muestra de entrenamiento
# X_test.shape          # Comentar/Descomentar para verificar el
tamaño de la muestra para comprobación
Y_test.shape
```

Se escalan los valores de las input y output entre 0 y 1 para mejorar el rendimiento:

```
#from sklearn.preprocessing import MinMaxScaler
#scaler = MinMaxScaler()
#scaler.fit(X_train)
#MinMaxScaler(copy=True, feature_range=(0, 1))
#X_train = scaler.transform(X_train)
#X_test = scaler.transform(X_test)
```

Se importan los módulos necesarios para crear la red:

```
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
```

Se añaden las diferentes capas a la red:

```
model = Sequential()

model.add(Dense(1))                                     # Entrada/Input layer
model.add(Dense(25, activation = 'relu'))
model.add(Dense(100, activation = 'relu'))
model.add(Dense(200, activation = 'relu'))
model.add(Dense(250, activation = 'relu'))
model.add(Dense(200, activation = 'relu'))
model.add(Dense(100, activation = 'relu'))
model.add(Dense(25, activation = 'relu'))
model.add(Dense(25))                                    # Salida/Output layer

model.compile(optimizer = 'adam', loss='mse', metrics=['mae'])
```

Entrenamiento de la red:

```
EPOCHS = 500
history = model.fit(x=X_train, y=Y_train, epochs=EPOCHS, batch_size
=100, validation_data=(X_test, Y_test))
```

Representación de la función de pérdidas (loss) y otros indicadores:

```
loss_mm = pd.DataFrame(model.history.history)
loss_mm.plot()
```

Evaluamos la capacidad de predicción de la red:

```
test_predictions = model.predict(X_test)
test_predictions = pd.Series(test_predictions.reshape(500,))
Y_test = pd.Series(Y_test.reshape(500,))
pred_mm = pd.DataFrame(Y_test, columns = ['True'])
pred_mm = pd.concat([pred_mm, test_predictions], axis=1)
pred_mm.columns = ['True', 'Model predictions']
sns.scatterplot(x='True', y='Model predictions', data=pred_mm)
```

Representamos uno de los casos "reales" (calculado por el modelo) y comparamos con la predicción de la red:

```
time=np.linspace(0, 1, num=25)
real_displacement = np.zeros((25,))
predict_displacement = np.zeros((25,))
for i in range(0, 25):
    real_displacement[i] = Y_test[i];
    predict_displacement[i] = test_predictions[i]
plt.plot(time, real_displacement, label="Real")
plt.scatter(time, predict_displacement, marker='o', label="Predicción")
plt.xlabel("tiempo (s)")
plt.ylabel("Desplazamiento (mm)")
plt.legend(loc='lower right')
```

Obtenemos los datos de uno de los casos "reales" (calculado por el modelo) y la predicción de la red:

```
print_real_displacement=np.vstack((time, real_displacement))
print_predict_displacement=np.vstack((time, predict_displacement))
name1 = my_data_dir + 'real_displacement.txt'
name2 = my_data_dir + 'predict_displacement.txt'
np.savetxt(name1,print_real_displacement.T, delimiter=',')
np.savetxt(name2,print_predict_displacement.T, delimiter=',')
```

Anexos E

Muestras utilizadas en el entrenamiento de las redes neuronales

En este anexo, se presentan las distintas muestras empleadas en el entrenamiento de la red neuronal, tanto para el modelo idealizado, el modelo fusiforme y el modelo vasto intermedio.

E.1. Modelo idealizado

Las Figuras E.1, E.2, E.3 y E.4 muestran los resultados del desplazamiento en la dirección Z del extremo del paralelepípedo para distintas variables de entrada para 100 muestras generadas. Mientras que las Figuras E.5, E.6 y E.7 muestran los resultados del desplazamiento en la dirección Z del extremo del paralelepípedo para distintas variables de entrada para 1000 muestras generadas.

E.2. Modelo fusiforme

En este caso, las Figuras E.8, E.9, E.10 y E.11 muestran los resultados del desplazamiento en la dirección Z del extremo del octavo de músculo para distintas variables de entrada.

E.3. Modelo vasto intermedio

Por ultimo, la Figura E.12 muestra los resultados del desplazamiento en la dirección Z del extremo del músculo vasto intermedio utilizando como variable de entrada la

tensión isométrica máxima.




Figura E.1: Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 .




Figura E.2: Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada los parámetros a y b .




Figura E.3: Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 y los parámetros a y b .




Figura E.4: Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la carga externa aplicada y los parámetros a y b .




Figura E.5: Población de 1000 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 .




Figura E.6: Población de 1000 muestras utilizadas en el entrenamiento de la red, utilizando como entrada los parámetros a y b .




Figura E.7: Población de 1000 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 y los parámetros a y b .




Figura E.8: Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 .




Figura E.9: Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada los parámetros a y b .




Figura E.10: Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 y los parámetros a y b .




Figura E.11: Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la carga externa aplicada y los parámetros a y b .




Figura E.12: Población de 100 muestras utilizadas en el entrenamiento de la red, utilizando como entrada la tensión isométrica máxima, P_0 .